

UNIVERSIDAD DE CUENCA

**FACULTAD DE CIENCIAS QUÍMICAS
ESCUELA DE INGENIERÍA AMBIENTAL**



PREDICCIÓN DE CAUDALES EN LA CUENCA DEL MACHÁNGARA

**TESIS DE GRADO PREVIA A LA OBTENCIÓN DEL TÍTULO
DE INGENIERO AMBIENTAL**

AUTOR:

NESTOR DANIEL QUITO TORRES

DIRECTOR:

ING. ALEX MANUEL AVILÉS AÑAZCO Msc.

CUENCA, Mayo del 2015

RESUMEN

La dependencia por el agua en todas las actividades diarias alrededor del mundo ha generado el deseo de saber cuánta lluvia y caudal puede existir en un lugar determinado. En este estudio se presenta un modelo de predicción de lluvia y caudal para la microcuenca del Labrado y Chanlud.

Se determinó tres variables climáticas que más influencia tienen con la lluvia de las dos microcuencas a través de una matriz de correlación. Luego de tener las tres variables climáticas se procedió a realizar dos metodologías para la predicción de la lluvia a través de un modelo ARIMA y de redes neuronales artificiales (RNAs). En el sistema ARIMA se planteó solo un modelo con la lluvia como variable de entrada y en las redes neuronales se generó 16 modelos para cada zona. Las variables de entrada en las RNAs fueron los tres predictores potenciales y la lluvia de cada microcuenca. Las RNAs fueron las seleccionadas para la predicción de lluvia en cada microcuenca a través de parámetros estadísticos como: el error cuadrático medio, error absoluto medio y del coeficiente de Nash-Sutcliffe.

La lluvia pronosticada se utilizó en la predicción del caudal. Se plantearon dos metodologías; la primera metodología es las RNAs y el otro fue un modelo híbrido que combina el método ARIMA y las RNAs. Se seleccionó al mejor modelo a través de parámetros estadísticos anteriormente mencionados.

Palabras claves: Predicción de lluvia y caudales, RNAs, variables climáticas, ARIMA.

ABSTRACT

The dependence on water in all daily activities around the world has generated a desire to know how much rain and streamflow can exist in a particular place. In this study occurs a model for forecast rain and streamflow in the basin of Labrado and Chanlud.

It was determined three climatic variables that most influence has with rain of the two basins through a correlation matrix. After having three climatic variables proceed to make two methodologies for predicting rain through an ARIMA model and artificial neural networks (RNAs). In the system ARIMA only was proposed one model with the rain as input variable and in the neural networks was generated 16 models for each zone. The input variables in the RNAs were the three potential predictors and the rain of each basin. The RNAs were selected for the prediction of rain in each basin through statistical parameters such as: mean square error, mean absolute error and Nash-Sutcliffe coefficient.

The predicted rain was used in predicting streamflow. Two methodologies were raised; the first method is the RNAs and the other was a hybrid model that combines the ARIMA method and RNAs. We selected the best model through statistical parameters mentioned above.

Keywords: Forecast of rain and streamflow, RNAs, climatic variables, ARIMA

Tabla de contenido

RESUMEN.....	2
ABSTRACT	3
Glosario.....	12
CAPITULO I	13
ASPECTOS GENERALES	13
1.1. Introducción	14
1.2. Justificación	14
1.3. Objetivos	15
1.3.1. Objetivo General.....	15
1.3.2. Objetivos Específicos	16
1.4. Descripción de la zona de Estudio	16
1.4.1. Ubicación.....	16
1.4.2. Clima de la zona.....	18
1.4.3. Hidrografía.....	20
CAPITULO II	24
ANÁLISIS DE LA PRECIPITACIÓN DE LAS MICROCUENCAS CON LA UTILIZACIÓN DE DATOS CLIMÁTICOS REGIONALES Y/O GLOBALES.....	24
2.1. Introducción	25
2.2. Marco Teórico	25
2.2.1. Estado del arte de fenómenos, índices y variables climáticos que tienen relación con la precipitación en las microcuencas.....	28
2.3. Metodología.....	30
2.3.1. Análisis de los datos de precipitación de las microcuencas	30
2.3.2. Obtención de las variables e índices climáticos regionales y/o globales de páginas webs	30
2.3.3. Obtención de la matriz de correlación	31
2.3.4. Fundamentos para la selección de los posibles predictores climáticos de mayor influencia en la precipitación de las microcuencas	32
2.4. Resultados.....	33
2.4.1. Coeficientes de Correlación	33
2.4.2. Prueba de Significancia	34
CAPITULO III	36
PREDICIÓN DE LA LLUVIA EN LAS 2 MICROCUENCAS	36
3.1. Introducción	37



3.2. Marco Teórico	37
3.2.1. Estado del arte de los modelos seleccionados	37
3.2.2. Descripción de los modelos seleccionados	38
3.3. Aplicación de las RNAs en la predicción de lluvia mensual en las microcuencas de El Labrado y Chanlud.....	46
3.3.1. Prototipos planteados para realizar en el modelo RNAS	47
3.4. Aplicación del modelo ARIMA en la predicción mensual de lluvia en las 2 microcuencas de estudio	48
3.5. Selección del modelo que mejor se adapta a la lluvia de las microcuencas	49
3.5.1. Descripción de los estimadores utilizados	49
3.5.2. Determinación de la Red Neuronal Artificial que mejor se ajusta a la lluvia de cada microcuenca	51
3.5.3. Determinación de la serie que mejor se ajusta entre el modelo ARIMA y la Red Neuronal Artificial seleccionada	51
3.5.4. Predicción de la lluvia	51
3.6. Resultados.....	51
3.6.1. Modelos planteados en RNAs para la predicción de la lluvia en cada microcuenca.....	51
3.6.2. Red neuronal artificial seleccionada	55
3.6.4. Determinación del mejor modelo entre la RNAs y el ARIMA.....	59
3.6.5. Predicción de la lluvia.....	59
CAPITULO IV:.....	61
PREDICCION DEL CAUDAL	61
4.1. Introducción	62
4.2. Modelo de RNAs.....	62
4.3. Modelo Híbrido.....	63
4.4. Evaluación de los modelos	66
4.5. Resultados.....	67
4.5.1. Selección de Modelo de RNAs	67
4.5.2. Modelo Híbrido realizado	70
4.5.3. Selección del mejor modelo para la predicción del caudal	75
Capítulo V	77
Conclusiones y Recomendaciones	77
5.1. Sobre el Análisis de la precipitación.....	78



5.2. Sobre la predicción de la precipitación	78
5.3. Sobre la predicción de los caudales.....	79
5.4. Recomendaciones.....	80
Bibliografía.....	81
ANEXOS:.....	85
Anexo 1.- Datos de las variables macroclimáticas	85
Anexo 2: Datos de Lluvia y caudales de la microcuenca El Labrado.....	100
Anexo 3.- Datos de Lluvia y caudales de la microcuenca Chanlud.....	107
Anexo 4.- Descripción sistemática de la realización de RNAs en NeuralTools 6.3 ..	110
Anexo 6 Determinación de modelo ARIMA en IBM SPSS Statistics 20.0.....	119

Índice de Figuras

Figura 1.- Ubicación de cuenca del Machángara	17
Figura 2.- Localización de las represas en la cuenca del rio Machángara	18
Figura 3.- Temperatura promedio mensual en El Labrado	19
Figura 4.- Precipitación total anual en El Labrado.....	20
Figura 5.- Localización de las Microcuencas de estudio	21
Figura 6.- Red hidrográfica de la Microcuenca Chanlud	22
Figura 7.- Hidrografía de la zona de estudio	23
Figura 8.- Distribución de los bloques del ENSO.....	27
Figura 9.- combinación del SPS para el nodo j.....	42
Figura 10.- Reporesentación grafica de las funciones de activación	44
Figura 11.- Predicciones de la lluvia en la microcuenca El Labrado	60
Figura 12.- Predicciones de la lluvia en la microcuenca Chanlud.....	60
Figura 13.- Gráfica del modelo 12 en la microcuenca El Labrado	70
Figura 14.- Gráfica del modelo 12 en la microcuenca Chanlud	70
Figura 15.- Grafica de diferentes transformaciones del caudal del Labrado para ajustarla a una distribución normal.....	71
Figura 16.-Grafica de diferentes transformaciones del caudal del Chanlud para ajustarla a una distribución normal.....	72
Figura 17.- Predicción del caudal con el modelo hibrido para la microcuenca El Labrado	75
Figura 18.- Predicción del caudal con el modelo hibrido para la microcuenca Chanlud	75
Figura 19.- Ventana inicial de NeuralTools 6.3	111
Figura 20.- Iconos para la aplicación de las RNAs.....	111
Figura 21.- Ventana de la opción "Administrador del Conjunto de Datos"	112
Figura 22.- Determinación de tipo de variable	113
Figura 23.- Opciones para el entrenamiento de la red	113
Figura 24.- Opciones para guardar la red entrenada.....	115
Figura 25.- Selección de la arquitectura de la red	116
Figura 26.- Condiciones de la red MLF	117
Figura 27.- Condiciones para la finalización del entrenamiento.....	118



Figura 28.- Verificación del entrenamiento	119
Figura 29.- Definición de fechas de conjunto de análisis	120
Figura 30.- Determinación del formato de las fechas	121
Figura 31.- Creación del modelo	122
Figura 32.- Selección del modelo ARIMA	123

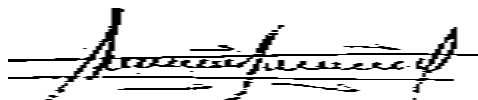
Índice de Tablas

Tabla 1.- Resumen del área, altura, pendientes.....	23
Tabla 2.- Coordenadas Geográficas de los bloques del ENSO	27
Tabla 3.- Datos utilizados en cada microcuenca de estudio.....	31
Tabla 4.- Resultados en la zona de El Labrado	33
Tabla 5.- Resultados de la zona El Chanlud	34
Tabla 6.- Determinación del valor p y su relación con su nivel de significación en El Labrado.....	35
Tabla 7.- Determinación del valor p y su relación con su nivel de significación en el Chanlud.....	35
Tabla 8.- Designación de los meses para el período de entrenamiento y validación de la red.....	47
Tabla 9.- Simbología para la formación de prototipos para la RNAs	48
Tabla 10.- Prototipos planteados para el análisis la precipitación (P) en RNAs	48
Tabla 11.- Modelos entrenados en RNAs	52
Tabla 12.- Influencia de las entradas en el entrenamiento de cada red en la zona de El Labrado.....	53
Tabla 13.- Influencia de las entradas en el entrenamiento de cada red en la zona de El Chanlud.....	54
Tabla 14.- Errores determinados para cada modelo en “El Labrado”	56
Tabla 15.- Errores determinados para cada modelo en la zona de “El Chanlud”	56
Tabla 16.- Ajustes del Modelo ARIMA para la microcuenca El Labrado	58
Tabla 17.- Ajustes del Modelo ARIMA para la microcuenca Chanlud.....	58
Tabla 18.- Comparación en función de los errores entre el modelo ARIMA y la RNAs .	59
Tabla 19.- Modelos para la predicción el caudal mensual (Q_m) en RNAs.....	63
Tabla 20.-Modelos para la predicción del $RICE_t$ en RNAs.....	66
Tabla 21.- Evaluación de los modelos de predicción de caudales con RNAs en El Labrado.....	67
Tabla 22.- Evaluación de los modelos de predicción de los caudales con RNAs en la zona el Chanlud.....	68
Tabla 23.- Determinación de la mejor alternativa para ajustarla a una distribución normal con datos de caudal de EL Labrado	71
Tabla 24.- Determinación de la mejor alternativa para ajustarla a una distribución normal con datos de caudal de Chanlud.....	71
Tabla 25.- Valor de variables a utilizar para cada microcuenca.....	72
Tabla 26.- Modelo ARIMA para cada zona.....	73
Tabla 27.- Errores en la predicción $RICE_t$ en cada modelo de RNA en Chanlud	73
Tabla 28.-Errores en la predicción $RICE_t$ para cada modelo de RNA en El Labrado	73
Tabla 29.- Selección del modelo de predicción a través de la RECM	76

CLÁUSULA DE DERECHO DE AUTOR

Yo, Nestor Daniel Quito Torres, autor de la tesis “PREDICCIÓN DE CAUDALES EN LA CUENCA DEL MACHÁNGARA”, reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de Ingeniero Ambiental. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 18 de Mayo del 2015.

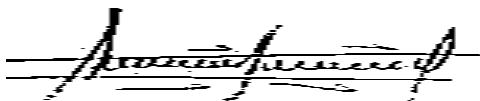


Nestor Daniel Quito Torres
C.I: 0106509540

CLÁUSULA DE PROPIEDAD INTELECTUAL

Yo, Nestor Daniel Quito Torres, autor de la tesis “PREDICCIÓN DE CAUDALES EN LA CUENCA DEL MACHÁNGARA”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 18 de Mayo del 2015.



Nestor Daniel Quito Torres
C.I: 0106509540

AGRADECIMIENTO:

Agradezco a Dios Todopoderoso por haberme dado salud y vida durante toda mi carrera universitaria.

Al ingeniero, Alex Avilés Añazco, director de esta tesis, quien desde el planteamiento de este proyecto me apoyo con su revisión y sus conocimientos profesionales para conseguir los objetivos planteados.

Al Instituto Nacional de Meteorología e Hidrología y al Consejo de la cuenca del Machángara que me facilitaron la información para la realización de esta investigación.

DEDICATORIA:

Dedico a todas las personas que me apoyaron en todo momento sin importar en la situación en la que me encontraba.

A mi madre, Rosa Quito Torres, quien desde que nací me ha apoyado en cualquier reto de mi vida; en especial durante mi vida estudiantil por creer que soy capaz de salir adelante por mí mismo y luchar por todas las metas estudiantiles propuestas.

A mi hermana, la Lcda. Elisa Cusco, quien desde pequeños fuimos como uno solo y que siempre tuvimos como objetivo el de ser profesionales y lo hemos cumplido.

A mi esposa, Magdalena Naula y a mi hijo, Christopher Quito, quienes desde que están conmigo son el motivo de luchar por un mejor despertar y sé que con la ayuda de Dios cada día, ese despertar irá mejorando.

Glosario

ETAPA EP: Empresa Pública Municipal de Telecomunicaciones Agua Potable, Alcantarillado y Saneamiento Ambiental de Cuenca

IGM: Instituto Geográfico Militar

INAMHI: Instituto Nacional de Meteorología e Hidrología del Ecuador

ACP: Análisis de Componentes Principales

ENSO: El Niño Southern Oscillation

TSM: Temperatura de la Superficie del Mar

IOS: Índice de Oscilación Sur

KNMI: Instituto Meteorológico de Holanda

CPC: Centro de Predicción del Clima de los Estados Unidos

PDO: Oscilación Decadal del Pacífico

ONI: Índice Oceánico del Niño

CP: Componentes Principales

RNAs: Redes Neuronales Artificiales

AR: Modelos Autorregresivos

MA: Modelos de Medias Móviles

ARIMA: Modelo Autorregresivo Integrados de Media Móvil

MLF: Red Neuronal de Perceptrón Multicapas

GRNN: Red Neuronal de Regresión Generalizada

PN: Red Neuronal Probabilística

RECM: Raíz de Error Cuadrático Medio

EAM: Error Absoluto Medio

ICE: Índice de Caudal Estandarizado

RICE: Residual del Índice de Caudal Estandarizado



CAPITULO I

ASPECTOS GENERALES

1.1. Introducción

La problemática que existe alrededor del mundo, con respecto a la escasez del agua afecta directamente a la población en los sectores urbanos, agrícolas, industriales, etc. Una de las medidas para ayudar a disminuir este impacto hacia todos los pobladores es la capacidad de determinar la cantidad de agua disponible en los meses siguientes, esto permitiría tomar medidas que disminuyan la escala del impacto. En esta investigación se tratará de encontrar modelos que se adapten al comportamiento hidrológico (precipitación y caudal) en dos microcuencas del Machángara. Las dos microcuencas en estudio son El Labrado y Chanlud.

1.2. Justificación

La afección agrícola generada por las sequías, produce una reducción en la producción de los diferentes productos agrícolas y por lo tanto un perjuicio a la economía de los hogares y de los agricultores. Según, el Consejo de la cuenca del Machángara (2014), la cantidad de hectáreas (ha) irrigadas a lo largo de la cuenca del río Machángara llegan a 1,300, que son abastecidas por dos canales denominados Machángara y Checa-La Dolorosa. En términos de habitantes, la población beneficiada por los proyectos de riego en la zona de estudio asciende a 3,100 agricultores.

La afección al sector industrial también es relevante sobre todo a la industria energética. El Ecuador se encamina hacia un cambio en la matriz energética (buscando la soberanía de la misma) a través de la producción de energía usando recursos renovables, como es el caso de las centrales hidroeléctricas que necesitan del agua para producir energía. Entonces podemos observar que la generación de hidro-energía depende exclusivamente de la cantidad de agua disponible; existiendo problemas en épocas de estiaje (por ejemplo, el racionamiento de energía eléctrica en la población). También las centrales hidroeléctricas tienen que cumplir con el caudal ecológico para la zona y en épocas de sequía tienen que reducir el caudal para la generación eléctrica para cumplir con dicho caudal. En la zona de estudio se produce alrededor de 38.4 Mega-watios, en sus dos centrales (Saymirín y Saucay) que reciben

agua de dos embalses llamados Labrado y Chanlud (Consejo de la cuenca del Machángara, 2014; ElecAustro, 2014).

Las plantas de potabilización también se ven afectadas por la falta de agua en épocas de sequía, ocasionando un menor suministro de agua potable para la población. En la ciudad de Cuenca la escasez del líquido vital para el consumo humano no se ve tan afectada en épocas de verano, debido a las grandes reservas naturales de agua ubicadas en las partes altas de las cuencas que rodean la ciudad. Sin embargo, existen sectores rurales que si son afectados por la disminución del agua, esto se debe a la poca investigación de los gestores del agua para determinar épocas de escasez y así poder tomar decisiones que sirvan para mitigar este impacto. Según el Consejo de la cuenca del Machángara (2014), esta cuenca abastece aproximadamente a 140,000 habitantes de la ciudad de Cuenca con la planta de potabilización de Tixán que es administrada por la Empresa Pública Municipal de Telecomunicaciones Agua Potable Alcantarillado y Saneamiento Ambiental de Cuenca (ETAPA EP), potabilizando alrededor de 600 litros por segundo (l/s).

Los problemas indicados anteriormente podrían disminuir mediante la predicción de caudales y así poder tener la información suficiente para una priorización del recurso hídrico en los diferentes usos. Es por esto la importancia de esta investigación enfocada en el pronóstico de las lluvias y caudales mensuales a través de predictores climáticos, dado que estas herramientas ayudarían a la toma de decisiones y generar medidas para mitigar los problemas expuestos.

1.3. Objetivos

1.3.1. Objetivo General

- Predicción de caudales mensuales en las microcuencas de El Labrado y Chanlud a través de predictores climáticos potenciales.

1.3.2. Objetivos Específicos

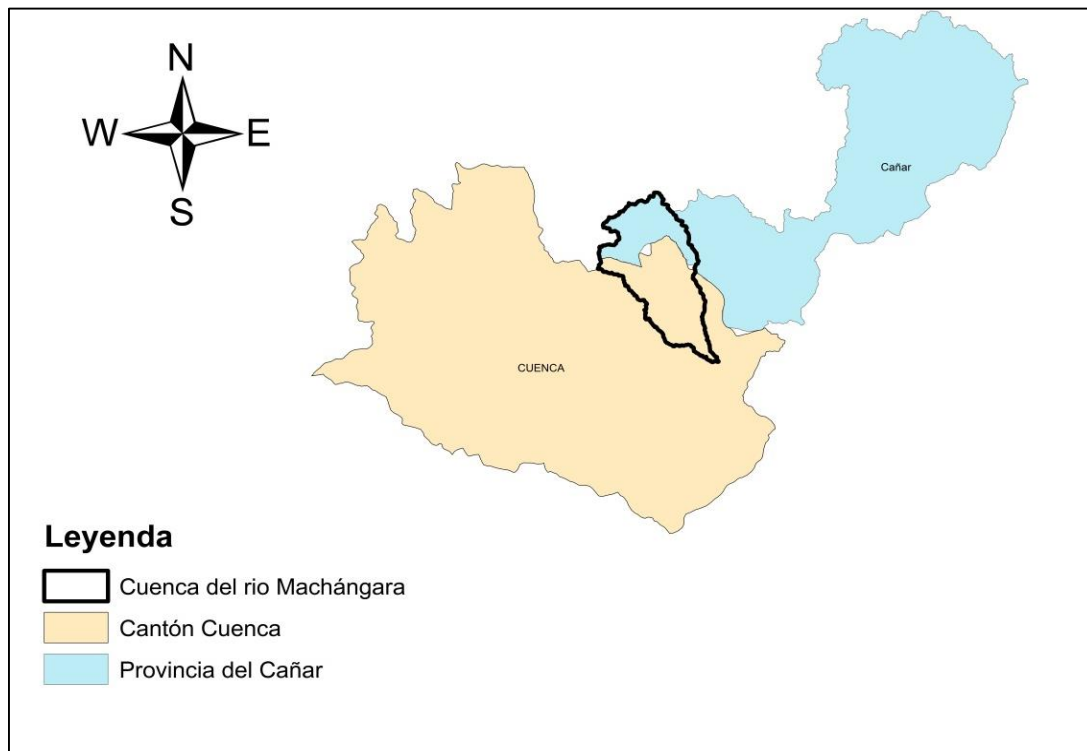
- Analizar la precipitación de las microcuencas con el uso de datos climáticos regionales y/o globales a través de una matriz de correlaciones.
- Utilizar 2 modelos diferentes para la predicción de la precipitación y caudal en las 2 microcuencas.
- Comparar los modelos utilizados en la predicción de lluvias y caudales a través del desempeño de cada modelo, usando parámetros estadísticos para la evaluación como: Error Cuadrático Medio (ECM), Error Absoluto Medio (EAM) y el Coeficiente de eficiencia de Nash-Sutcliffe (E).

1.4. Descripción de la zona de Estudio

1.4.1. Ubicación

La cuenca del río Machángara, se encuentra ubicada en su mayor parte de superficie en la provincia del Azuay (cantón Cuenca) y una pequeña porción en la provincia del Cañar (Figura 1). La cuenca tiene una superficie de 32,500 ha. Los principales poblados que se encuentran en la cuenca del río Machángara y que pertenecen al cantón Cuenca son: Checa, Chiquintad, Sinincay, Sayausí, Ricaurte, Octavio Cordero, Sidcay, entre otros. También se encuentra la zona del parque industrial de la ciudad de Cuenca, que cuenta con aproximadamente 133 industrias. A la cuenca también pertenecen poblados de la provincia del Cañar como es el caso de: Deleg, Jerusalén, Nazón y San Antonio del cantón Cañar. La población existente en todos estos poblados oscila alrededor de 69,000 habitantes (Villavicencio y Chávez, 2011; Consejo de la cuenca del Machángara, 2014).

Figura 1.- Ubicación de cuenca del Machángara

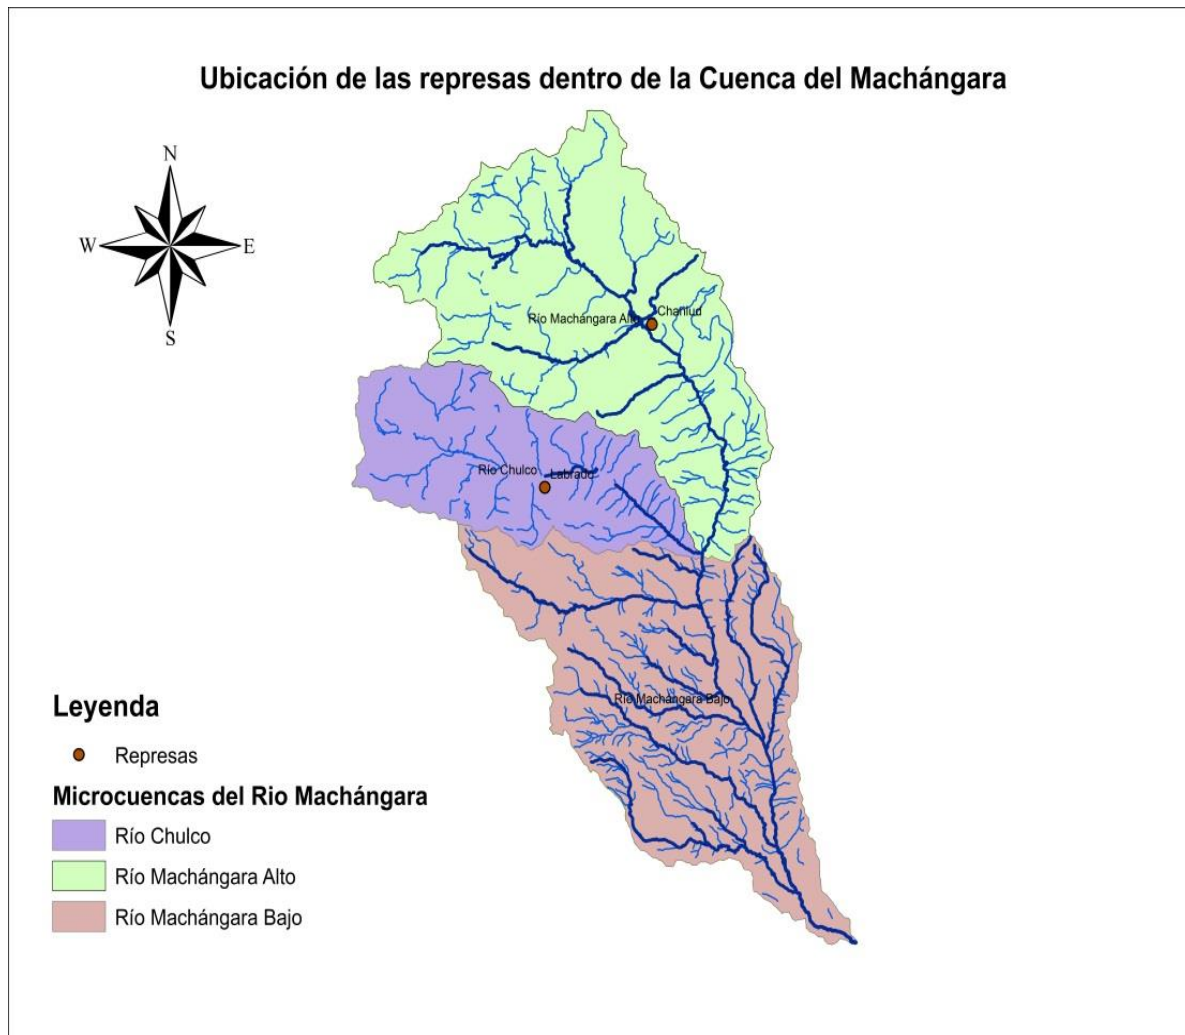


Fuente: (Geo Portal del Instituto Geográfico Militar, Ecuador, 2014)

Realizado por: (Quito N, 2014)

En la zona también existen centrales hidroeléctricas manejadas por la empresa ELECAUSTRO. Estas centrales se alimentan del recurso hídrico a través de sus dos represas ubicadas en la parte alta de la sub cuenca (Figura 2). La represa “Chanlud” se encuentra a una altitud de 3,500 m.s.n.m., tiene una capacidad de almacenamiento de 17 millones de m³ en una altura de 51 m y un caudal regulado de 4.8m³/s. Mientras la represa “El Labrado”, puede almacenar 6.20 millones de m³, cuya construcción tiene una altura de 13m y se encuentra aproximadamente a la misma altura de la represa Chanlud (ElecAustro, 2014; Villavicencio y Chávez, 2011; Consejo de la cuenca del Machángara, 2014).

Figura 2.- Localización de las represas en la cuenca del río Machángara



Fuente: (Geo Portal del Instituto Geográfico Militar, Ecuador, 2014)

Realizado por: (Quito N, 2014)


1.4.2. Clima de la zona

1.4.2.1. Temperatura

En la microcuenca “El Labrado”, el promedio mensual de la temperatura media diaria para un periodo de 32 años es de 8.5 °C, teniendo una mínima y máxima de 6.2°C y

10.6 °C respectivamente; de igual manera podemos observar en la Figura 3 que las épocas más frías son desde el mes Junio hasta septiembre.

Figura 3.- Temperatura promedio mensual en El Labrado




Fuente:(INAMHI)

Realizado por: (Quito, N)

1.4.2.2. Precipitación

En el Labrado el promedio anual y mensual de lluvias es de aproximadamente 1,283 mm y 93.43 mm respectivamente. En Chanlud el promedio anual de lluvia es de 1,466 mm y el promedio mensual de 123.3 mm. En la figura 4 se puede observar la precipitación total anual en la microcuenca El Labrado.

Figura 4.- Precipitación total anual en El Labrado



Fuente: (INAMHI)

Realizado por: (Quito, N)

1.4.3. Hidrografía

La subcuenca del Machángara equivale el 5% del territorio total de la cuenca del Paute (6,441.90 km²). Las microcuencas en estudio se encuentran en la parte alta del Machángara (Figura 5).

Figura 5.- Localización de las Microcuencas de estudio

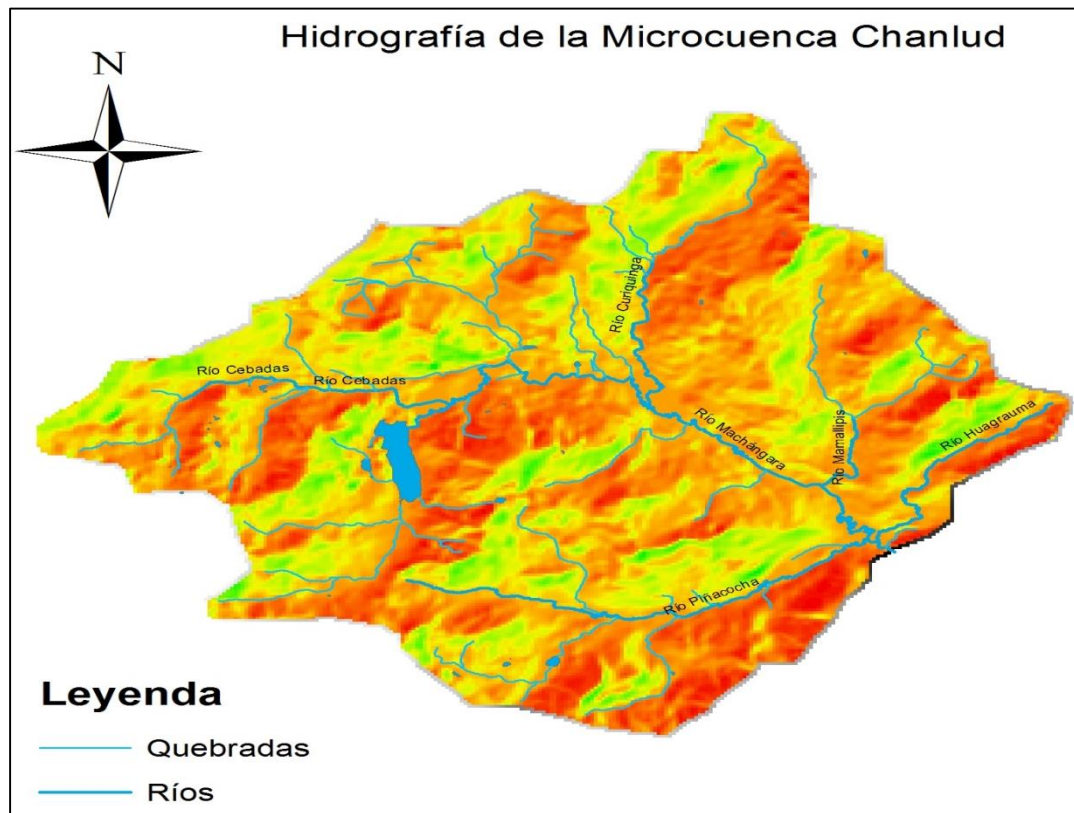


Fuente: (Geo Portal del Instituto Geográfico Militar, Ecuador, 2014)

Realizado por: (Quito N, 2014)

Según los datos cartográficos del Instituto Geográfico Militar (IGM), la microcuenca del Chanlud comienzan con la intersección de los ríos Curiquina y Cebada a una altura aproximada de 3,720 m.s.n.m (Figura 6), en la cual se puede observar que la dirección de río es de Oeste a Este. Existen otros afluentes del río Machángara, como son los ríos Mamallipis, Piñacocha y Huagrahuma.

Figura 6.- Red hidrográfica de la Microcuenca Chanlud

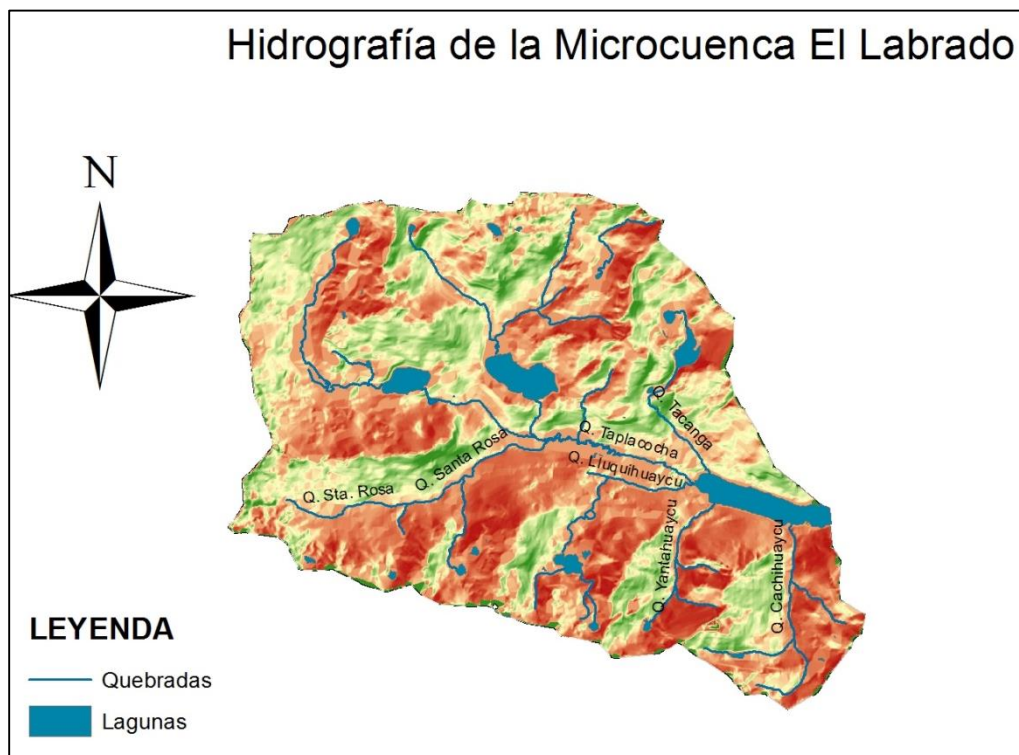


Fuente: (Geo Portal del Instituto Geográfico Militar, Ecuador, 2014)

Realizado por: (Quito N, 2014)

La Microcuenca del Labrado está formado por varias quebradas como: Santa Rosa, Tacanga, Taplacochoa, Chanludpungu, Chachihuaycu (Figura 7).

Figura 7.- Hidrografía de la zona de estudio



Fuente: (Geo Portal del Instituto Geográfico Militar, Ecuador, 2014)

Realizado por: (Quito N, 2014)

Por último en la tabla 1 se presenta la información de la altura y sus respectivas pendientes.

Tabla 1.- Resumen del área, altura, pendientes

	Área (km ²)	Altitud media (m.s.n.m)	Pendiente media en grados
Machángara	325.446	3894	20.60
Labrado	40.121	4048	23.41
Chanlud	89.186	4081	18.43



CAPITULO II

ANÁLISIS DE LA PRECIPITACIÓN DE LAS MICROCUENCAS CON LA UTILIZACIÓN DE DATOS CLIMÁTICOS REGIONALES Y/O GLOBALES

2.1. Introducción

En este capítulo se va a analizar la relación de la precipitación de las microcuencas en estudio con información regional y/o global; a través de una matriz de correlación. Al final de este capítulo se presentará los posibles predictores de lluvia para cada microcuenca. El procedimiento a seguir es el siguiente:

- Análisis de los datos de precipitación de las microcuencas
- Obtener variables e índices climáticos regionales y/o globales
- Realizar el análisis a través de una matriz de correlación
- Obtener los posibles predictores que influye en la precipitación de las microcuencas

2.2. Marco Teórico

Se describirán estudios que sustenten la selección de variables y/o índices climáticos en el desarrollo de esta investigación.

En primer lugar definiremos que es un índice y que es una variable climática. Un índice climático es el resultado de formulaciones matemáticas que utilizan valores de variables climáticas y las variables climáticas son aquellas observadas y registradas en una estación meteorológica. También existen fenómenos climáticos que se dan alrededor del mundo y que afectan al clima de un determinado lugar; como el fenómeno El Niño Southern Oscillation (ENSO).

A continuación se describirán los índices climáticos, variables climáticas y el fenómeno del ENSO que se utilizarán en este estudio.

Temperatura Superficial del Mar (TSM)

Es la variable que mide la temperatura a la que se encuentra la superficie del mar. La superficie de medición puede variar dependiendo el método utilizado. Por ejemplo un satélite radiométrico determina la temperatura de la superficie en un milímetro de

profundidad; a comparación de barcos que miden la temperatura a una profundidad de 5 metros (Rossel, 1997).

Las mediciones de esta variable se realizan en diferentes coordenadas geográficas (tabla 2) y una de sus funciones, es la determinación de los índices de ENSO.

El Niño Southern Oscillation (ENSO)

Este es un fenómeno natural, que se caracteriza por un recalentamiento del Océano Pacífico, y un debilitamiento de la circulación de Walker. La circulación de Walker, es una celda de circulación atmosférica que se desarrolla sobre el pacífico ecuatorial y empuja los vientos del océano del este al oeste. Existe una gran confusión entre el ENSO y El Niño. El fenómeno del Niño es una alteración regional y se enfoca en las anomalías del océano Pacífico oriental mientras que el ENSO es un conjunto de condiciones atmosféricas y oceánicas de gran escala en todo el océano Pacífico y que aparecen con los recalentamientos del mar de la parte oriental (Rossel, 1997).

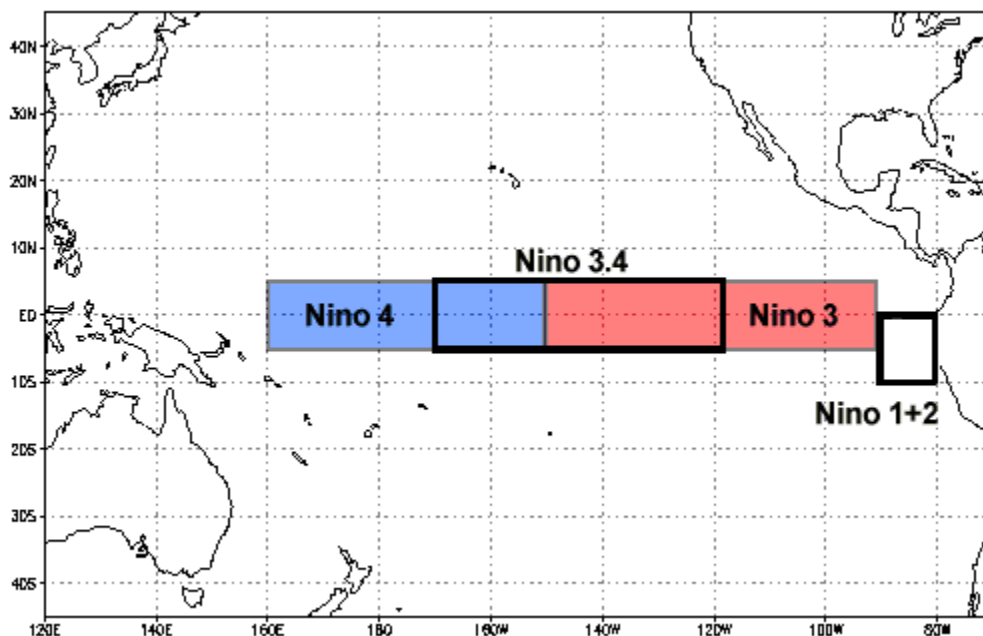
Para una mejor comprensión del fenómeno se han definido 4 índices en diferentes regiones del Océano Pacífico, que van de este a oeste, que resultan de la media de las anomalías mensuales de la temperatura superficial del mar (Tabla 2 y Figura 8), llamados: NIÑO 1, NIÑO 2, NIÑO 3 y NIÑO 4. Pero la pequeña diferencia que existía entre los 2 primeros bloques hizo que se reagrupen en NIÑO1+2, además para tener un mejor análisis también se generó un nuevo bloque llamado NIÑO 3.4 que se encuentra entre el NIÑO 3 y 4. Estos cuatro bloques son los más utilizados para la previsión del ENSO (Jiménez, 2008; Rossel, 1997; Wright y otros, 1984).

Tabla 2.- Coordenadas Geográficas de los bloques del ENSO

Nombre	Coordenadas
NIÑO 1+2	0°-10°S, 90°-80°W
NIÑO 3	5°N-5°S, 150°-90°W
NIÑO 3.4	5°N-5°S, 170°W-120°W
NIÑO 4	5°N-5°S, 160°E-150°W

Fuente: (Wright y otros, 1984; Ashok et al. 2007)

Figura 8.- Distribución de los bloques del ENSO



Fuente: (NOAA, 2014)

Índice de Oscilación Sur (IOS)

Este índice es el resultado del cálculo aritmético de las diferencias de la presión del aire a nivel del mar entre Tahití y Darwin, Australia. Así, cuando el IOS es negativo, se

presentan anomalías positivas en la temperatura superficial del mar (calentamiento de las aguas) en el Pacífico ecuatorial central y oriental. Cuando son valores positivos, existen anomalías negativas en la temperatura superficial del mar, es decir las aguas de océano pacífico se enfrían (Arntz y Fahrbach, 1996; Troup, 1965).

Oscilación Decadal del Pacífico (PDO)

Este índice se calcula usando el ACP de las anomalías mensuales en la temperatura superficial del Océano Pacífico en la parte Norte. Para separar la variabilidad de dicho patrón del calentamiento global, se remueve la media mensual global de las anomalías de temperatura superficial del mar (Poveda, 2004).

El PDO tiene 2 fases durante su período que es la fase cálida y la fase fría, con valores positivos y negativos respectivamente. Pero cada una de estas fases permanece durante un período de tiempo significativo a diferencia de las otras variables. Entre este período de tiempo se puede diferenciar un período corto que dura como 10 años y un período largo que dura alrededor de unos 40 años; sin embargo no es inusual que estos períodos se rompan con un cambio de fase que dura 1 a 5 años.¹

Índice Oceánico del Niño (ONI)

Promedio móvil de tres meses de la anomalía de temperatura de superficie del mar (TSM) en la región del ENSO 3.4. Este índice es la principal medida para hacer un seguimiento y predecir el ENSO (De La Casa y Nasello ,2012; Ramirez y Jaramillo, 2009).

2.2.1. Estado del arte de fenómenos, índices y variables climáticos que tienen relación con la precipitación en las microcuencas

Según Rossel (1997), en su investigación llamada “Influencia de El Niño sobre los regímenes hidro-pluviométricos del Ecuador”, las condiciones climáticas, en especial la precipitación se ve muy afectada por este fenómeno. Existe un aumento de

¹ El PDO (Oscilación del Pacífico), <http://www.skepticalscience.com/translation.php?a=159&l=4>.

precipitación sobre las laderas de la cordillera de los Andes (Ecuador y Perú) y en el cono sur (Chile, Argentina y Uruguay).

También el Índice de Oscilación Sur (IOS), guarda una relación con el ENSO. La fase cálida de ENSO está asociada a un IOS bajo o negativo (Puertas y Carvajal, 2011).

Heredia y Loza (1999), realizó un estudio comparativo de los efectos del ENSO en los caudales mensuales de la cuenca de río Esmeraldas, cuenca amazónica del Napo y cuenca del Paute. Se utilizaron datos de caudales y el índice del Niño 1+2 para determinar una relación. Los resultados muestran la existencia de una correlación significativa entre Niño 1+2 y los volúmenes anuales de agua en el ingreso al embalse Amaluza en Paute.

Mora y Willems (2012), en su investigación *Decadal oscillations in rainfall and air temperature in the Paute River Basin Southern Andes of Ecuador*, examinaron en tiempo y espacio las anomalías de precipitación y temperatura de datos mensuales observados en 16 a 25 estaciones ubicadas en la cuenca del río Paute. Se utilizaron los índices del ENSO como el NIÑO 1+2, NIÑO 3, NIÑO 3.4 y la presión del nivel del mar (SLP) en la estación de Darwin-Tahití que genera el Índice de Oscilación del Sur. Además, también se consideran los datos correspondientes a la TSM del Atlántico tropical del Sur (SST TSA), la Oscilación del Pacífico Tropical, la Oscilación del Pacífico Este (SST EPO) y lluvias del noreste de Brasil. En relación a la lluvia concluyen que la temporada septiembre a noviembre muestra correlaciones negativas altas con el índice NIÑO 1+2, lluvias del noreste de Brasil y correlaciones positivas con el SST TSA en regímenes de alta montaña con dirección noreste. Mientras en el periodo de marzo a mayo muestra una correlación positiva con el NIÑO 1+2 para algunas estaciones occidentales.

2.3. Metodología

2.3.1. Análisis de los datos de precipitación de las microcuencas

Los datos de precipitación que utilizaremos para las microcuencas fueron facilitados por el INAMHI, cuya serie para “El Labrado”, comienza en Enero de 1964 y termina en Diciembre del 2009, mientras para “Chanlud”, la serie inicia en Junio de 1988 y termina en Diciembre del 2011. La información de lluvia obtenida tiene vacíos en algunos meses y esto se debe a múltiples causas, como: mal funcionamiento de los instrumentos meteorológicos, caída de la energía, el operador no ha ido a revisar, etc. Es por eso que en los meses faltantes de información van a ser reemplazados por el promedio de los meses de los años anteriores. Los datos de la precipitación se presentan en el anexo 2 y 3.

2.3.2. Obtención de las variables e índices climáticos regionales y/o globales de páginas webs

Las variables e índices que se utilizó en cada microcuenca se presentan en la tabla 3. Esta información mensual se pudo encontrar en las siguientes páginas:

Climate Explorer, esta página que almacena información climática y también realiza análisis estadísticos de los datos climáticos. Esta página es administrada por el Instituto Meteorológico de Holanda (KNMI). Iniciando en 1999 como una página web simple para analizar teleconexiones del ENSO y ha crecido a lo largo de los años a más de 1 terabytes (TB) de datos climáticos y docenas de herramientas de análisis. Uno de sus campos de aplicación, es la alta resolución paleoclimatológica (Estudio del clima de épocas geológicas antiguas) y además es de libre acceso (Climate Explorer, 2014; Trouet y Van Oldenborgh ,2013).

Otra página con datos climáticos es la Climate Prediction Center, que pertenece a la Administración Nacional Oceánica y Atmosférica (NOAA) de los Estados Unidos. Tiene una base de datos de diferentes variables e índices macroclimáticos, monitoreados en tiempo real. En esta página también se dan evaluaciones de los orígenes de las principales anomalías climáticas. Los administradores de la página

buscan que las aplicaciones de sus bases de datos y sus predicciones sirvan para mitigar desastres naturales relacionados con el clima y es puesta al público para el bien social y económico en la agricultura, la energía, el transporte, los recursos hídricos y la salud (Climate Prediction Center,2014).

Tabla 3.- Datos utilizados en cada microcuenca de estudio

Zona	Datos a utilizar	Serie de tiempo
El Labrado	NIÑO 1+2	Enero 1964 - Diciembre 2009
	NIÑO 3	
	NIÑO 3.4	
	PDO	
	ONI	
	IOS	
	TSM ²	
Chanlud	NIÑO 1+2	Junio 1988-Diciembre del 2011
	NIÑO 3	
	NIÑO 3.4	
	PDO	
	ONI	
	IOS	
	TSM ³	

Se incluyeron estos índices y variables porque el estudio se centra en la utilización de información determinada en el océano Pacífico.

2.3.3. Obtención de la matriz de correlación

Al tener la información para realizar el análisis de la lluvia en las microcuencas; se procedió a realizar este análisis a través de la matriz de correlación de Pearson.

² y ³ El TSM utilizado es el medido cerca de las costas del Ecuador con coordenadas geográficas de 0°-10°S, 90°-80°W (TSM del NIÑO 1+2).

La Matriz de Correlación de Pearson

La correlación es la medida precisa para conocer si existe algún tipo de relación entre dos variables, es así que este grado de asociación puede cuantificarse mediante el cálculo del coeficiente de correlación. La medida más habitual para el estudio de la correlación es el coeficiente de correlación de Pearson que viene dada por la siguiente expresión:

$$r_{xy} = \frac{\sum x_i y_i}{N S_x S_y} - \bar{x}\bar{y} \quad \text{Ecuación 1}$$

Dónde:

x_i, y_i = variables estudiadas

\bar{x}, \bar{y} = medias de la variables estudiadas

S_x, S_y = desviación estándar

N = Número total de datos

2.3.4. Fundamentos para la selección de los posibles predictores climáticos de mayor influencia en la precipitación de las microcuencas

El rango del coeficiente de correlación (r_{xy}) varía entre -1 a 1. Si la relación es 1 o -1, indica una correlación lineal perfecta; pero si el valor varía de 0 a 1 quiere decir que tienen una relación directa entre la variables (las dos aumentan al mismo tiempo) y si el valor va de 0 a -1, existe una relación inversa (una variable disminuye a medida que otra aumenta). El coeficiente de correlación es muy utilizado para determinar la relación existente entre 2 variables (Díaz y Fernández, 2001; Puertas y Carvajal, 2011).

Una vez calculado r_{xy} , interesa saber si tal valor es o no significativo, es decir comprobar si las variables están realmente relacionadas o presentan relación como consecuencia del azar.

Para ello se utilizará la prueba t Student, en donde se plantean la hipótesis nula (H_0) y alternativa (H_i):

$$H_0: r_{xy} = 0$$

$$H_i: r_{xy} \neq 0$$

t Student ofrece la información necesaria para contrarrestar la hipótesis nula de que la correlación obtenida no procede de una población cuyo r_{xy} es 0. Por lo tanto, necesitamos rechazar H_0 para poder afirmar que existe una relación en realidad. El estadístico t para la correlación de Pearson (r_{xy}) es:

$$t = \frac{r_{xy}\sqrt{N-2}}{\sqrt{1-r_{xy}^2}} \quad \textbf{Ecuación 2}$$

Una vez determinado el estadístico t y los grados de libertad, podemos determinar el valor de p utilizando la tabla de valores de distribución t Student. El valor p es comparado con un nivel de significación (α , alfa) previamente definido. Para rechazar H_0 se debe cumplir la siguiente condición: $p < \alpha$ (Pita y Pértega,1997; Díaz y Fernández 2001).

Los valores de alfa utilizados son 0,05 y 0.01.

La determinación de los coeficientes de correlación y la prueba de significancia se lo realizará en el programa IBM SPSS Statistics 20.

2.4. Resultados

2.4.1. Coeficientes de Correlación

Luego de realizar el análisis de correlación, se obtuvieron los resultados (tabla 4 y 5) para poder determinar los predictores potenciales.

Tabla 4.- Resultados en la zona de El Labrado

Matriz de correlaciones								
Variables	Lluvia (mm)	IOS	NIÑO1+2	NIÑO 3	NIÑO 3.4	PDO	TSM (°C)	ONI
Lluvia (mm)	1	0.106	0.024	-0.035	-0.086	0.011	0.312	-0.115

Tabla 5.- Resultados de la zona El Chanlud

Matriz de correlaciones								
Variables	Lluvias (mm)	IOS	NIÑO 1+2	NIÑO 3	NIÑO 3.4	PDO	TSM(°C)	ONI
Lluvias (mm)	1	0.13	-0.02	-0.076	-0.119	-0.089	0.209	-0.159

Como se explicó en la metodología, el coeficiente de correlación varía entre -1 a 1 y los datos macroclimáticos seleccionados, deben acercarse a estos dos extremos.

En el Labrado, la temperatura sobre el nivel de mar (TSM) es la que mejor correlación tiene con 0.312, seguido por dos predictores con correlaciones casi similares pero diferenciadas por el signo que son: el Índice de oscilación sur (IOS) con un valor de 0.106 y el Índice oceánico del niño (ONI) con un valor de - 0.115. Por ultimo hay un grupo de variables que tienen un bajísimo coeficiente de correlación con respecto a la precipitación que son: NIÑO 1+2, NIÑO 3, NIÑO 3.4 y PDO, con coeficientes de 0.024, -0.035, -0.086 y 0.011 respectivamente.

En Chanlud (Tabla 5), la TSM con 0.209 es la que mejor correlación tiene. A continuación tenemos un grupo de variables como: el ONI, IOS y el NIÑO 3.4 con valores de: -0.159, 0.13 y -0.119 respectivamente. Finalmente otras variables con correlaciones muy bajas que son: PDO con -0.089, NIÑO 3 con -0.076 y cierra el NIÑO 1+2 con un valor de -0.02.

2.4.2. Prueba de Significancia

La significancia de cada microcuenca se presenta en la tabla 6 y 7, que nos ayudará a determinar que correlaciones no están relacionadas solo por el azar.

Tabla 6.- Determinación del valor p y su relación con su nivel de significación en El Labrado

	TSM($^{\circ}$ C)	IOS	NIÑO12	NIÑO 3	NIÑO 3.4	PDO	ONI
p valor	5.99E-14	0.013	0.575	0.417	0.044	0.8	0.007
	Condición $p < \alpha$ ($\alpha = 0.05$ o 0.01)						
	5,99E-14 < 0.01	0.013 < 0.05			0.044 < 0.05		0.007 < 0.01

Tabla 7.- Determinación del valor p y su relación con su nivel de significación en el Chanlud

	IOS	NIÑO 1+2	NIÑO 3	NIÑO 3.4	PDO	TSM($^{\circ}$ C)	ONI
p valor	0.029	0.74	0.200	0.045	0.133	3.90E-04	0.008
	Condición $p < \alpha$ ($\alpha = 0.05$ o 0.01)						
	0.029 < 0.05			0.045 < 0.05		3.90E-4 < 0.01	0.008 < 0.01

Aunque las correlaciones son bajas; tres índices y una variable en cada microcuenca cumplen con la condición para descartar H_0 ($p < \alpha$). En ambas microcuencas; el valor de p indica que el ONI y el TSM no provienen de una relación al azar con una certeza mayor al 99,99%. Mientras el valor de p de IOS y el NIÑO 3.4, rechazan H_0 con un 95% de certeza.

Los posibles predictores en ambas microcuencas son el TSM, ONI, IOS y el NIÑO 3.4; sin embargo este último está muy cerca de rebasar la condición $p < \alpha$ y por esta razón lo descartamos.

En conclusión los predictores potenciales para la predicción de la lluvia en las dos microcuencas son: la Temperatura Superficial del Mar (TSM), el Índice Oceánico del Niño (ONI) y el Índice de Oscilación Sur (IOS).



CAPITULO III

PREDICIÓN DE LA LLUVIA EN LAS 2 MICROCUENCAS

3.1. Introducción

Varios modelos han sido propuestos para predecir la lluvia en diferentes partes del mundo; muchos de ellos dependen exclusivamente de la variable a predecir, mientras otros están en función de otros tipos de variables que afectan el clima de la zona de estudio.

Entre los modelos más conocidos se encuentran los modelos de series de tiempo estocásticas y modelos de regresión lineal y no lineal. Sin embargo, existen otros modelos de predicción que manejan de una manera eficiente la aleatoriedad de los datos hidrometeorológicos y presentan una adaptabilidad fácil a nueva información; en estos modelos se incluyen las técnicas de Redes Neuronales Artificiales (RNAs), Sistemas Fuzzy (FS), y Sistemas Neuro-difuso (NFS) (Zúñiga y Jordán 2005).

En este trabajo se presenta la aplicación de los siguientes modelos: El ARIMA que se encuentra dentro del grupo de los modelos de serie estocástica y el modelo de Redes Neuronales Artificiales en cada microcuenca de estudio.

Para las RNAs se utilizarán los predictores seleccionados (resultados del capítulo 2) como variables de entrada y en el modelo ARIMA se utilizarán los datos previos de la lluvia.

3.2. Marco Teórico

3.2.1. Estado del arte de los modelos seleccionados

Rodríguez et al. (2000), realizó un estudio denominado pronóstico de la lluvia máxima en 24 horas en la zona cafetera. Los datos utilizados fueron de las estaciones ubicadas en río Cauca (19 estaciones) y para la predicción se utilizó el modelo ARIMA, con un período de 8 años (desde 1981 a 1988). La metodología utilizada para determinar el mejor modelo de predicción fue considerar aquel que de los menores residuos entre el pronóstico y el registrado. Se presentó un modelo ARIMA para cada estación que mejor se ajusta a la serie original.

Carvajal et al. (2011) realizó una investigación en 7 estaciones del valle del río cauca; relacionando varias variables e índices macroclimáticos a través de un análisis de componentes principales. De las 14 entradas utilizadas, se determinó que la

temperatura superficial del mar en zona Niño 4 y Niño 3.4 son los que tienen una mayor correlación con la hidrometeorología de la zona y por lo tanto fueron utilizados para la predicción de los caudales. En el pronóstico de caudales se utilizó las RNAs y los modelos de series estocásticas (AR, ARMA). Las RNAs presentan una mejor adaptación a la información de las 7 estaciones meteorológicas.

Un estudio realizado en Colombia por Pinos et al. (2011), sobre el pronóstico de caudales medios mensuales del río Caplina, en el cual, se aplicaron 10 modelos de redes neuronales artificiales (RNAs), y el modelo autorregresivo periódico de primer orden. Las redes neuronales artificiales desde el punto de vista de predicción de caudales mensuales, mostraron un comportamiento excelente en términos de las estadísticas de los errores de predicción; más aún cuando se comparó con un modelo autorregresivo periódico de primer orden, mostrando un grado superior de eficiencia en las predicciones realizadas, ya que presentan porcentajes de ajuste superiores al 80%, en comparación al 62% de modelo autorregresivo.

Campozano (2011), en su estudio “Análisis de la robustez de un modelo de redes neuronales para la predicción de caudal en la cuenca alta del río Paute”. Utilizó variables de entrada para la predicción diaria del caudal como la información de la precipitación de 9 estaciones y el caudal de una estación. Se entrenaron varias arquitecturas de redes neuronales y se determinó a través de parámetros estadísticos la red óptima. Una red neuronal de tipo multilayer perceptrón con una capa oculta de 25 neuronas fue la seleccionada. Este estudio se encuentra la aplicación de las RNAs en las microcuencas que estamos estudiando. Sin embargo, es una aplicación diaria y este estudio se realizará de forma mensual.

3.2.2. Descripción de los modelos seleccionados

3.2.2.1. Modelo ARIMA

El modelo ARIMA es una conjugación del modelo autorregresivo y de medias móviles al que se los integra una diferenciación.

Los modelos autorregresivos integrados de promedio móvil, que expresan la predicción de un tiempo t , en función a una combinación lineal de los datos previos. El ARIMA se puede representar como:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-1} - \sum_{i=1}^q \theta_i \varepsilon_{t-1} + \varepsilon_t \quad \text{Ecuación 3}$$

$$\Delta Y_t = Y_t - Y_{t-1}$$

En donde la d corresponde a las d diferencias que son necesarias para convertir la serie original en estacionaria, ϕ son los parámetros de la parte autorregresiva, θ_i son los parámetros pertenecientes a las medias móviles y por último ε_t es el error. Para de esta manera obtener una serie estacionaria; la cual da origen a un proceso autorregresivo integrado de promedio móvil (Chávez, 1997).

Con la información histórica de la serie en estudio se trata de averiguar qué modelo ARIMA (p,q,d) x ARIMA (P,Q,D) es susceptible de haber generado dicha serie con el fin de utilizarlo para obtener predicciones de valores futuros. Esto se realiza en 4 etapas:

- Identificación
- Estimación
- Validación
- Predicción

Identificación

Consiste en identificar qué modelo ARIMA se adaptaría mejor a las características de la serie. Para estacionar a la serie en estudio; primeramente se procede a estacionarizarla en su media; para ello determinamos los valores d (orden de diferenciación regular) y D (orden de la diferenciación estacional) para que la serie sea estacionaria en su media (estacionalidad en la media) y luego se estabiliza su varianza (estacionalidad en varianza). Para transformarlas en estacionarias en varianza es muy común utilizar las transformaciones Box-Cox. Estas transformaciones Box-Cox

permiten corregir varianzas desiguales y cumplir con el requisito de la estacionalidad (Casimiro, 2009; De La Fuente, 2012).

Una vez que la serie esta transformada en estacionaria (en media y varianza) se determinan los posibles valores de las órdenes tanto de la parte regular (autorregresiva p y medias móviles q) como de la parte estacional (autorregresiva P y medias móviles Q) (Casimiro, 2009; De La Fuente, 2012).

Estimación

Consiste en encontrar los parámetros del modelo que ayuden a minimizar el error cuadrático medio (ECM); debido a que mientras menor sea el ECM, el modelo tendrá mejor capacidad predictiva (Casimiro, 2009; De La Fuente, 2012).

La fórmula de este error se encuentra en la página 59 (ecuación 4).

Validación

La validación se centra exclusivamente en analizar si los residuos del modelo tienen un comportamiento a las perturbaciones del mismo; es decir si son semejantes al ruido blanco (Casimiro, 2009; De La Fuente, 2012).

El ruido blanco es un proceso estocástico que presenta media nula, varianza constante y covarianza nula.

Predicción

Este modelo determina una predicción puntual y su distribución de la probabilidad es completa para todos los valores futuros de la serie. Lo más usual para determinar a la serie como el predictor optimo es aquel que minimice el Error Cuadrático Medio (Casimiro, 2009; De La Fuente, 2012).

3.2.2.2. Modelo de Redes Neuronales Artificiales

Las RNAs son una semejanza al cerebro humano, es decir la unidad de una RNA es la neurona, que posee la capacidad limitada de calcular, que en general es la suma ponderada de sus entradas y luego aplica una función de activación para obtener una

señal que será transmitida a la siguiente neurona. Las neuronas artificiales, obtienen la información a partir de un vector de entrada o a consecuencia de estímulos recibidos de otras neuronas y proporcionar una salida única (López y Fernández, 2008; Izaurieta y Saavedra 2003; Salas, 2004).

Estructura de una RNAs


Una RNA está formada por:

La **Capa de entrada**, contiene la información a ser estudiada como la variable a predecir y las variables que influyen en la predicción (predictores). Estas en general son unidades pasivas en tanto que no modifican el valor o señal recibida. El objetivo principal de esta capa es la presentación a la red de los datos a modelar y distribuir en la red la información recibida a las capas siguientes. La **Capa de salida**, contiene las respuestas, una vez finalizado el procesamiento de la información; y cada unidad de salida es una función de las entradas ocultas. **Una o varias capas ocultas:** estas contienen los nodos o neuronas no observables, estas no mantienen contacto alguno con el exterior. En esta capa o capas se llevan a cabo el procesamiento básico de la información a través de una función de activación. Si la red contiene más de una capa oculta, cada unidad oculta es una función de la suma ponderada de las unidades de la capa oculta anterior. La misma función de activación se utiliza en todas las capas (García, 2005; IBM Knowledge Center, 2013; Socha y Ortiz, 2005).

Potenciales Post Sinóptico (PSP)

Los PSP determinan el valor “ x ” de entrada para cada nodo a través de la combinación de todas las señales que alcanzan a cada nodo (W_{jk}). Este proceso es una combinación lineal, en donde los coeficientes W_{jk} se denominan pesos (Figura 9). El W_{jk} está asociado a la conexión entre el nodo j y el nodo k .

Figura 9.- combinación del PSP para el nodo j



Fuente: (García, 2005)

El termino b_k es denominado umbral o “Bias” y hace de termino independiente en la combinación lineal del PSP. Tanto el término w_{jk} y b_k son números reales (García, 2005).

Función de activación o de transferencia

La función de activación se aplica en las neuronas que se encuentran a continuación de la operación PSP; es decir el valor “ x ” que se obtuvo en el PSP es la entrada para la función de activación. Una función de activación representa por lo tanto una operación o regla en virtud de la cual se calcula la señal de salida de un nodo determinado. La señal de salida producida será transmitida a otros nodos a través de las conexiones de la red, o bien representará la salida de red si el nodo en cuestión es un nodo de salida (García, 2005).

Existen diversas funciones de activaciones:

- Función lineal o identidad
- Función escalón
- Función sigmoidea
- Función gaussiana
- Función sinusoidal
- Función tangente hiperbólica

Función lineal o identidad: esta toma argumentos de valor real y los devuelve sin modificar. Este tipo de funciones se utilizan en redes de baja complejidad (López y Fernández, 2008; Socha y Ortiz, 2005).

Función escalón: que presenta salidas binarias, habitualmente entre (0,1) o (-1,1). En este caso, si la activación de la neurona es inferior a un determinado umbral, la información saliente se asocia a una determinada salida y de igual manera si es igual o superior al umbral se asocia con otra salida. En general las neuronas con este tipo de función de transferencia resultan fáciles de implementar, sus aplicaciones son limitadas y se restringen a problemas binarios (López y Fernández, 2008; Socha y Ortiz, 2005).

Función sigmoidea: se encuentra definido en un intervalo con límites superiores e inferiores. Las funciones sigmoideas se caracterizan por presentar una derivada siempre positiva e igual a cero en su límites asintóticos que toma su valor máximo cuando $x=0$. Así estas funciones aplican las reglas básicas de la función de escalón, con la ventaja adicional de que la derivada se encuentra definida en todo el intervalo, lo que permite emplear algoritmos de entrenamiento más avanzados (López y Fernández, 2008; Socha y Ortiz, 2005).

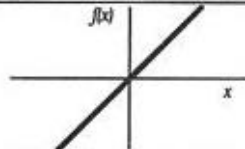
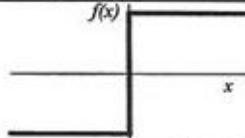
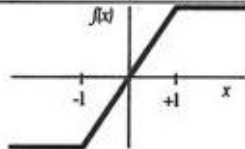
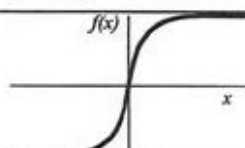
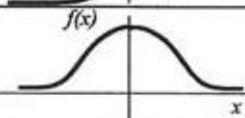
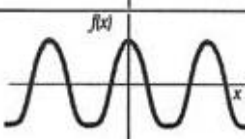
Función gaussiana: que adapta la forma de la campana de Gauss. Esta función es muy recomendable para aplicar a redes complejas con m capas ocultas ($m \geq 2$) (López y Fernández 2008; Socha y Ortiz, 2005).

Función sinusoidal: genera salidas continuas en el intervalo (-1, +1). Esta funciones suelen emplearse es los casos en los que se requiere explícitamente una periodicidad temporal (López y Fernández 2008; Socha y Ortiz, 2005).

Función tangente hiperbólica: esta función forma parte de las funciones sigmoidea por poseer similares características. Esta función tiene la siguiente forma: $\gamma(c) = \tanh(c) = (e^c - e^{-c}) / (e^c + e^{-c})$. Toma argumentos de valor real y los transforma al rango (-1, 1). (IBM Knowledge Center, 2013).

En la Figura 10, podemos ver de manera gráfica las funciones de activación o de transferencia conjuntamente con su rango.

Figura 10.- Representación grafica de las funciones de activación

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq 1 \\ +1, & \text{si } x > 1 \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Fuente: (Aguilar, 1999)

Arquitectura de RNAs

A continuación se describen algunos tipos de RNAs que son utilizados en varios estudios.

Perceptrón simple

Fue propuesta por el psicólogo, Frank Rosenblatt en el año de 1957. La arquitectura del perceptrón está compuesta por dos capas de neuronas; una de entrada y otra de salida. Este tipo de arquitectura neuronal, generalmente sirve para hacer una clasificación y su información de entrada es de tipo binaria. Su función de activación es de tipo escalón dando de esta manera solo salidas binaria con respuestas de 1 y 0. El

algoritmo de aprendizaje de este modelo es por corrección de errores (Bertona, 2005; Socha y Ortiz, 2005).

Perceptrón Multicapa (MLF)

Es una extensión del perceptrón simple. La topología de un perceptrón multicapa está definida por un conjunto de capas ocultas, una capa de entrada y una de salida. En esta arquitectura se puede utilizar cualquier tipo de función de activación. Este modelo es el más utilizado en la actualidad y con un espectro de aplicaciones. Son sistemas que pueden aproximar funciones complejas y por lo tanto modelar relaciones complejas entre variables independientes y una variable dependiente. El entrenamiento de una red MLF, consiste en encontrar una serie de pesos y términos de tendencia para las conexiones, que permitan que la red genere respuestas correctas cuando se presentan nuevos casos. Durante el entrenamiento obtenemos valores de error y a partir de estos valores se obtiene una media de error para este conjunto de entrenamiento completo. En un principio la red no funcionará demasiado bien debido a su asignación aleatoria inicial de pesos y hay que proceder con subsiguientes pruebas, que es la asignación de nuevos pesos; sin embargo esta asignación ya no será aleatoriamente y se lo realizará en función del algoritmo de entrenamiento, que selecciona pesos en función de los resultados de las pruebas anteriores (Bertona, 2005; Socha y Ortiz, 2005; Palisade, 2010).

Función base radial (RBF)

Las redes de RBF tienen una estructura muy simple, de baja complejidad computacional y un desempeño adaptivo superior. Este modelo es parte de las redes multicapa con conexiones hacia adelante y que tienen una sola capa oculta. El cálculo de la capa de salida se lo hace, en función de:

- La distancia euclídea a un punto denominado centro
- La función base radial (hay diferentes tipos a elegir y dependen de lo que va a determinar)
- El peso de salida

La arquitectura de la RBF, está formada por tres capas en total. La capa de entrada transmite a la capa oculta, sin realizar ninguna transformación; es decir no lleva pesos asociados. La capa oculta, realiza una transformación local y no lineal y por último la capa de salida, realiza una combinación lineal de las activaciones de la capa oculta⁴.

En esta arquitectura se encuentran las redes neuronales probabilísticas (PN) y las redes neuronales de regresión generalizada (GRNN).

Las redes PN son capaces de estimar límites de decisión no lineales mediante un enfoque óptimo Bayesiano. La principal utilización de esta red es en la clasificación de datos. Está formada por cuatro capas. La primera capa, donde se encuentran una determinada cantidad de neuronas. La siguiente capa se denomina capa de patrones y tiene n cantidad de neuronas. La tercera capa, con un k de neuronas que realiza una sumatoria y por ultimo una capa de decisión (Porrás y Moreno, 2013; Gutiérrez et al., 2013).

Las redes GRNN realizan una buena aproximación o mapeo de las funciones de entrada-salida, a partir de los datos de entrenamiento; es decir a medida que el conjunto de entrenamiento crece, el error se aproxima a cero. Para resolver cualquier problema con las GRNN, se debe tener una suficiente cantidad de datos, debido a que la cantidad de patrones que ingresan al sistema, es una variable limitante para estos diseños. Las redes GRNN se usan para aproximación de predicciones de funciones numéricas (Ballarín et al., 2005; Palisade, 2010).

3.3. Aplicación de las RNAs en la predicción de lluvia mensual en las microcuencas de El Labrado y Chanlud

Luego de la determinación de los posibles predictores (ver sección de resultados del Capítulo 2) que afectan a la lluvia de cada microcuenca o también llamados “predictores potenciales” (TSM, IOS y ONI), procedemos a determinar el conjunto de datos que nos servirán para la realización de las RNAs.

⁴<http://www.lab.inf.uc3m.es/~a0080630/redes-de-neuronas/base-radial.html>.

Los datos principales que se utilizaran son los tres predictores potenciales, que corresponden a las variables independientes del análisis, conjuntamente con la precipitación que en este caso sería la variable a predecir (variable dependiente). Se utilizará la misma serie de tiempo que se empleó para obtener la matriz de correlaciones. Para la microcuenca el Labrado fue de 45 años (enero 1964 – diciembre 2009) y para Chanlud, fue de 23 años (junio 1988 – diciembre 2011).

Como se explicó, las RNAs necesitan de un conjunto de datos para el entrenamiento y validación de la red. Para el período de entrenamiento se van a utilizar el 75% y para la validación 25% de la información.

La información de la lluvia fue registrada al final de cada microcuenca.

Tabla 8.- Designación de los meses para el período de entrenamiento y validación de la red

Lugar	Tiempo	Entrenamiento	Validación
El Labrado	Mensual	414 meses	138 meses
El Chanlud	Mensual	211 meses	72 meses

Se plantearon 2 conjuntos para el trabajo de las RNAs. En el primer conjunto para el entrenamiento y validación se seleccionaron de manera aleatoria. El segundo conjunto está formado con los primeros 75% de los datos ordenados de la serie de tiempo (entrenamiento) y el 25% restantes (últimos datos de la serie) son utilizados para la validación. La finalidad de utilizar los dos conjuntos es para determinar cómo influye en el entrenamiento de la red.

3.3.1. Prototipos planteados para realizar en el modelo RNAS

El planteamiento principal para la predicción de la precipitación en esta investigación es que la precipitación de un determinado mes está determinada por los valores de los predictores potenciales de los meses anteriores. De esta manera se han planteado varios prototipos para las RNAs, que incluyen datos de los tres predictores potenciales y también de la lluvia. De la TSM, ONI y IOS se eligieron hasta de 2 meses anteriores

para la predicción; y también se utilizó en varios prototipos a la lluvia del mes anterior. En la tabla 9 se describe la simbología de los valores a utilizar en cada prototipo y en la tabla 10, se exponen los prototipos planteados para las RNAs.

Tabla 9.- Simbología para la formación de prototipos para la RNAs

simbología de datos a utilizar	
p_{t-1}	precipitación de un mes anterior al deseado
IOS_{t-1}	índice de oscilación sur de 1 mes anterior al deseado
IOS_{t-2}	índice de oscilación sur de 2 meses anteriores al deseado
ONI_{t-1}	índice oceánico del niño de 1 mes anterior al deseado
ONI_{t-2}	índice oceánico del niño de 2 meses anteriores al deseado
TSM_{t-1}	temperatura superficial del mar de 1 mes anterior al deseado
TSM_{t-2}	temperatura superficial del mar de 2 meses anteriores al deseado

Tabla 10.- Prototipos planteados para el análisis la precipitación (P) en RNAs

Prototipos	Variables predictoras
1	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
2	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
3	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
4	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$

Como podemos ver en la tabla 10, se plantearon 4 prototipos con diferentes entradas y cada uno de ellos se trabajará con los 2 tipos de muestra la aleatoria y ordenada.

Las redes neuronales se ejecutaran en el programa NeuralTools 6.3, que es parte de un conjunto de programas denominados, “DecisionTools”, que nos sirven para analizar riesgos, realizar predicciones y realizar suposiciones. La descripción de la implementación de RNAs en NeuralTools se presenta en el anexo 4.

3.4. Aplicación del modelo ARIMA en la predicción mensual de lluvia en las 2 microcuencas de estudio

El programa IBM SPSS Statistics 20.0, es el utilizado para el modelo ARIMA. Este software tiene la capacidad de determinar directamente el modelo ARIMA que mejor

se ajusta al conjunto de datos. Cabe destacar que el único conjunto de datos que se utilizará en este método es el de la precipitación de cada microcuenca. La descripción del procedimiento en el programa se presenta en el anexo 5.

3.5. Selección del modelo que mejor se adapta a la lluvia de las microcuencas

Para esta selección; el primer paso es escoger el mejor tipo de RNAs de los 16 planteados (Tabla 11) en cada microcuenca, para luego ser comparado con el modelo ARIMA y así seleccionar el mejor para cada zona. Para determinar al mejor modelo que se ajusta a lluvia, lo vamos hacer a través de parámetros estadísticos como: el Error Cuadrático Medio (*ECM*), Error Absoluto Medio (*EAM*) y el coeficiente de eficiencia de Nash-Sutcliffe (*E*).

Al tener el modelo que mejor se ajusta a la lluvia se procede a la predicción de una serie de tiempo de la lluvia en ambos lugares, que posteriormente se usará como variable de entrada para el pronóstico del caudal (capítulo IV).

3.5.1. Descripción de los estimadores utilizados

Error Cuadrático Medio (*ECM*)

Permite evaluar la diferencia entre un valor estimado y el valor observado a través del promedio de los errores al cuadrado. Tener un error cuadrático medio de cero (0) es ideal pero esto no es posible en la mayoría de las situaciones. Un *ECM* de 0 significa que el estimador predice las observaciones con una precisión perfecta. Otra medida de las predicciones es la raíz cuadrada de este error cuadrático Medio (*RECM*), y es el que se empleará debido a que los dos programas utilizados nos dan este parámetro⁵.

Viene dada por la siguiente ecuación:

$$ECM = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Ecuación 4}$$

⁵ http://www.ehowenespanol.com/definicion-error-cuadratico-medio-hechos_130449/.

$$RECM(mm) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Dónde:

n = número de datos utilizados

y_i = valor observado

\hat{y}_i = valor pronosticado

Error Absoluto Medio (EAM)

Este error es muy similar al error cuadrático medio y viene dado por la siguiente formula:

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Ecuación 5}$$

Dónde:

n = número de datos utilizados

y_i = valor observado

\hat{y}_i = valor pronosticado

Coeficiente de eficiencia de Nash-Sutcliffe (E)

E es un indicador adimensional ampliamente utilizado en la evaluación de modelos hidrológicos, caracterizada por su flexibilidad a ser aplicado a diversos tipos de modelos matemáticos. El coeficiente varía de $-\infty$ hasta 1. Si $E=1$, indica que el valor pronosticado es igual al observado. Los valores que se acercan más a la unidad reflejan un mejor comportamiento del modelo (Besteiro y Gaspari 2012).

Viene dado por la siguiente formula:

$$E = 1 - \frac{\sum_{i=1}^n (Q_m - Q_p)^2}{\sum_{i=1}^n (Q_m - \bar{Q})^2} \quad \text{Ecuación 6}$$

Dónde:

Q_m = valor observado

Q_p = valor pronosticado

\bar{Q} = valor promedio de las observaciones

3.5.2. Determinación de la Red Neuronal Artificial que mejor se ajusta a la lluvia de cada microcuenca

La selección de la red neuronal artificial que mejor se ajusta en cada microcuenca se lo realizará en función a la raíz del error cuadrático medio (*RECM*) error absoluto medio (*EAM*) y del coeficiente de Nash-Sutcliffe (*E*).

3.5.3. Determinación de la serie que mejor se ajusta entre el modelo ARIMA y la Red Neuronal Artificial seleccionada

Luego de la selección de la mejor red neuronal, la comparamos con el modelo ARIMA y así determinamos quien tiene el mejor rendimiento en cada microcuenca. Para la determinación de este modelo se va a hacer en función al *RECM*, *EAM* y el coeficiente *E*.

3.5.4. Predicción de la lluvia

Con el modelo que mejor se ajusta al comportamiento de la lluvia en las dos microcuencas; procedemos a predecir una serie de tiempo de precipitación que nos servirá para el pronóstico del caudal. La serie de tiempo para el Labrado va ser desde Enero del 1964 hasta Diciembre del 2009; mientras para la microcuenca Chanlud la predicción es de Julio de 1988 hasta Diciembre del 2010.

3.6. Resultados

3.6.1. Modelos planteados en RNAs para la predicción de la lluvia en cada microcuenca

Como se explicó en la metodología se usaron los 4 prototipos planteados para las dos redes neuronales que ofrece el software NeuralTools (MLF y PN/GRNN); se obtuvieron 16 modelos para el entrenamiento y validación tanto para El Labrado como para Chanlud; 8 modelos con la muestra ordenada (4 modelos con la red MLF y 4 con la red PN/GRNN) y 8 modelos con la muestra aleatoria y así mismo cuatro con cada red. En la tabla 11 podemos ver los dieciséis modelos realizados con sus respectivas variables de entrada y las redes utilizadas. Cabe destacar que el software determinó a

la red GRNN de conjugación PN/GRNN esto se debe a que, lo que se está entrenado son variables numéricas y no categóricas.

El modelo MLF trabaja con la tangente hiperbólica como función de activación en la capa oculta y la función identidad en la capa de salida. También se trabajó con dos capas ocultas y con dos nodos en cada capa.

Tabla 11.- Modelos entrenados en RNAS

Modelos	Red	Prototipo	Muestra utilizada	Variables predictoras
1	MLF	1	Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
2	GRNN		Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
3	MLF		Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
4	GRNN		Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
5	MLF	2	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
6	GRNN		Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
7	MLF		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
8	GRNN		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
9	MLF	3	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
10	GRNN		Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
11	MLF		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
12	GRNN		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
13	MLF	4	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
14	GRNN		Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
15	MLF		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
16	GRNN		Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$

También podemos cuantificar el impacto de cada una de las entradas en el entrenamiento (Tabla 12 y 13), de cada modelo planteado tanto con la muestra aleatoria y la ordenada. Esta información nos permite determinar el porcentaje que intervienen las entradas en el entrenamiento de cada red. En estas dos tablas el modelo (No), está representado con el mismo número de la tabla 11.

Cuanto menor sea el valor del porcentaje para una entrada de entrenamiento, menos afecta esta entrada en las predicciones de una red determinada. Sin embargo hay que

tomar en cuenta que el resultado del impacto es en relación a esa red. El hecho de que una red aprendió a hacer caso omiso de una entrada dada, no significa que otro tipo diferente de red no encuentre contribuciones significativas de esta entrada en las predicciones. El impacto de una entrada en el programa utilizado viene dado por la siguiente formula:

$$\text{Impacto de una entrada } a = \frac{\Delta_a}{\Delta_a + \Delta_b + \dots + \Delta_n} \times 100 \quad \text{Ecuación 7}$$

$$\Delta_a = (V_{max} - V_{min})$$

Dónde:

V_{max} = valor máximo pronosticado con la entrada a

V_{min} = valor mínimo pronosticado con la entrada a

Tabla 12.- Influencia de las entradas en el entrenamiento de cada red en la zona de El Labrado

Impactos de las entradas en el entrenamiento de la red dentro de la muestra aleatoria								
El Labrado								
No	Red	TSM_{t-1}	ONI_{t-1}	IOS_{t-1}				
1	MLF	41.35%	35.49%	23.14%				
2	GRNN	57.4384%	42.0508%	0.5108%				
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}			
5	MLF	34.13%	26.67%	18.50%	20.68%			
6	GRNN	49.49%	39.80%	0.36%	10.34%			
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}		
9	MLF	29.81%	21.15%	10.75%	23.81%	14.45%		
10	GRNN	48.58%	40.51%	0.03%	10.63%	0.23%		
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}	ONI_{t-2}	IOS_{t-2}
13	MLF	29.42%	9.66%	4.41%	27.14%	12.57%	9.00%	7.77%
14	GRNN	22.18%	18.26%	1.21%	9.49%	0.82%	14.66%	33.33%
Impactos de las entradas en el entrenamiento de la red dentro de la muestra ordenada								
El Labrado								
	Red	TSM_{t-1}	ONI_{t-1}	IOS_{t-1}				
3	MLF	10.54%	85.27%	4.17%				
4	GRNN	60.30%	36.85%	2.83%				
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}			
7	MLF	31.98%	23.58%	26.33%	18.09%			

8	GRNN	58.38%	33.31%	2.58%	5.7109%			
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}		
11	MLF	32.22%	14.49%	15.92%	17.44%	19.91%		
12	GRNN	59.78%	21.68%	5.97%	4.91%	7.64%		
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}	ONI_{t-2}	IOS_{t-2}
15	MLF	19.53%	12.33%	8.25%	18.79%	10.94%	13.36%	16.76%
16	GRNN	32.01%	10.76%	0.72%	8.11%	18.20%	0.39%	29.78%

Tabla 13.- Influencia de las entradas en el entrenamiento de cada red en la zona de El Chanlud

Impactos de las entradas en el entrenamiento de la red dentro de la muestra aleatoria								
Chanlud								
No	Red	TSM_{t-1}	ONI_{t-1}	IOS_{t-1}				
1	MLF	37.63%	32.19%	30.17%				
2	GRNN	55.66%	44.23%	0.10%				
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}			
5	MLF	28.15%	26.40%	11.60%	33.84%			
6	GRNN	32.86%	23.47%	0.92%	42.72%			
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}		
9	MLF	22.99%	16.80%	8.17%	24.33%	27.69%		
10	GRNN	32.72%	15.31%	0.45%	39.86%	11.64%		
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}	ONI_{t-2}	IOS_{t-2}
13	MLF	18.83%	17.81%	17.60%	9.65%	10.23%	14.55%	11.30%
14	GRNN	32.46%	16.94%	0.48%	39.94%	9.67%	0.24%	0.24%
Impactos de las entradas en el entrenamiento de la red dentro de la muestra ordenada								
EL Chanlud								
	Red	TSM_{t-1}	ONI_{t-1}	IOS_{t-1}				
3	MLF	27.51%	46.29%	26.18%				
4	GRNN	49.80%	49.57%	0.62%				
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}			
7	MLF	21.43%	28.95%	27.38%	22.22%			
8	GRNN	42.77%	17.31%	2.35%	37.55%			
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}		
11	MLF	33.48%	15.06%	11.18%	18.50%	21.76%		
12	GRNN	39.91%	14.07%	1.20%	31.76%	13.03%		
		TSM_{t-1}	ONI_{t-1}	IOS_{t-1}	p_{t-1}	TSM_{t-2}	ONI_{t-2}	IOS_{t-2}
15	MLF	14.41%	12.22%	12.89%	18.54%	16.19%	10.80%	14.91%
16	GRNN	40.91%	14.09%	0.82%	31.75%	11.59%	0.61%	0.20%

En el entrenamiento de las 16 redes en el Labrado (Tabla 12) podemos observar que para el entrenamiento, el que aportó mayor información fue la temperatura superficial del mar del mes anterior (TSM_{t-1}), en casi todos los modelos a excepción de modelo 3 que toma mayor información de variable ONI_{t-1} con un 46,29%.

La variable que menos influencia tiene en el entrenamiento es el IOS_{t-1} . De los 16 modelos, 11 modelos tienen a esta variable como el que menor información aporta a la red, seguido por la precipitación de un mes anterior al deseado (p_{t-1}) encontrándose en dos modelos (7 y 12). Los otros 3 modelos restantes que difieren de las anteriores variables: son el modelo 11 con el ONI_{t-1} , modelo 14 con TSM_{t-2} y modelo 16 con ONI_{t-2} .

Mientras tanto en la tabla 13 podemos ver los resultados de los impactos de cada uno de las variables en el entrenamiento para la microcuenca Chanlud y se determina que la variable que mayor información aporta es la TSM_{t-1} a 8 modelos, seguida por la p_{t-1} a 5 modelos y en los tres restantes modelos la variable que aporta mayor información es el ONI_{t-1} (en 2 modelos) y la TSM_{t-2} (un modelo). De igual manera como en la microcuenca de El Labrado el IOS_{t-1} es el que menor información aporta en esta microcuenca para la calibración de la red en 11 modelos; seguidos del IOS_{t-2} en 2 modelos.

3.6.2. Red neuronal artificial seleccionada

De los 16 modelos de cada zona, pudimos determinar los siguientes valores de la *RECM*, *EAM* y el coeficiente *E*:

Tabla 14.- Errores determinados para cada modelo en “El Labrado”

EL Labrado						
Modelos	Tipo de red	RECM (mm)	EAM (mm)	Coeficiente E	Tipo de muestra	Variables
1	MLF	38.71	30.51	0.263	Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
2	MLF	38.62	30.59	0.208	Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
3	GRNN	37.85	28.73	0.251	Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
4	GRNN	39.29	30.97	0.180	Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
5	MLF	38.57	29.53	0.268	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
6	MLF	38.43	29.88	0.216	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
7	GRNN	38.66	30.36	0.265	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
8	GRNN	39.04	30.82	0.191	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
9	MLF	38.62	30.01	0.266	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
10	MLF	38.34	30.11	0.220	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
11	GRNN	38.56	30.30	0.269	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
12	GRNN	38.93	30.70	0.195	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
13	MLF	38.79	30.40	0.260	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
14	MLF	37.70	29.84	0.246	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
15	GRNN	32.22	24.74	0.490	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
16	GRNN	32.89	25.92	0.426	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$

Tabla 15.- Errores determinados para cada modelo en la zona de “El Chanlud”

Chanlud						
modelos	Tipo de red	RECM (mm)	EAM (mm)	Coeficiente E	Tipo de muestra	Variables
1	MLF	37.70	28.88	0.365	Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
2	MLF	31.96	24.98	0.431	Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
3	GRNN	37.85	28.73	0.360	Aleatoria	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
4	GRNN	34.30	25.81	0.387	Ordenada	$P=f(IOS_{t-1}, ONI_{t-1}, TSM_{t-1})$
5	MLF	37.66	27.83	0.366	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
6	MLF	31.24	23.88	0.535	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
7	GRNN	32.73	24.57	0.522	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
8	GRNN	31.60	24.08	0.555	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, ONI_{t-1})$
9	MLF	37.73	28.48	0.364	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
10	MLF	31.30	23.90	0.584	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
11	GRNN	31.37	23.53	0.561	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
12	GRNN	29.62	22.46	0.630	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1})$
13	MLF	37.21	27.79	0.382	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
14	MLF	31.26	24.51	0.528	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$

15	GRNN	31.36	23.50	0.561	Aleatoria	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$
16	GRNN	29.84	22.66	0.622	Ordenada	$P=f(p_{t-1}, IOS_{t-1}, IOS_{t-2}, TSM_{t-1}, TSM_{t-2}, ONI_{t-1}, ONI_{t-2})$

En la tabla 14 podemos observar que en el Labrado por lo general los errores van disminuyendo a medida que se van dando más variables dentro de una red. En el primer grupo de modelos que van del 1 al 4 con entradas de TSM_{t-1} , IOS_{t-1} , ONI_{t-1} , se puede determinar que la red con mejor rendimiento en términos *RECM* y *EAM* es el No 3 con un 37.85 mm y un 28.73 mm. El segundo conjunto de modelos que van del 5 al 8; cuyas entradas son: p_{t-1} , IOS_{t-1} , TSM_{t-1} y ONI_{t-1} ; el No 6 tiene un *RECM* de 38.43 mm y un valor de 29.53mm de *EAM* que presenta el No 5. En tercer grupo de modelos que son desde el 9 hasta el 12 cuyas variables son: p_{t-1} , IOS_{t-1} , TSM_{t-1} , TSM_{t-2} , ONI_{t-1} ; el No 10 presenta un *RECM* de 38.34 mm; mientras en términos de *EAM* el No 9 tiene mejor rendimiento. En el último grupo de 4 modelos (del 13 al 16) con p_{t-1} , IOS_{t-1} , IOS_{t-2} , TSM_{t-1} , TSM_{t-2} , ONI_{t-1} y ONI_{t-2} como entradas; se encuentra el modelo que mejor rendimiento tiene de todos los 16 modelos y por lo tanto el que será seleccionado para la predicción de la lluvia, siendo el No 15 que fue realizado con una muestra aleatoria y entrenada con una red GRNN, cuya *RECM* y *EAM* son: 33.22 mm y 24,74 mm respectivamente.

Mientras en la tabla 15 están los valores de los errores obtenidos para la microcuenca Chanlud. El primer grupo del No 1 al 4 con entradas de TSM_{t-1} , IOS_{t-1} , ONI_{t-1} , podemos ver que el No 2 tienen la *RECM* y el *EAM* más bajo con 31.96 mm y 24,98 mm respectivamente. El segundo conjunto que va desde el 5 hasta el No 8 con variables como: p_{t-1} , IOS_{t-1} , TSM_{t-1} y ONI_{t-1} , podemos ver que de nuevo coinciden los menores errores en un solo modelo que es el No 6, con *RECM* de 31.24 mm y un *EAM* de 23.88 mm. El antepenúltimo conjunto (del 9 al 12) con entrada de: p_{t-1} , IOS_{t-1} , TSM_{t-1} , TSM_{t-2} , ONI_{t-1} , el No 12 es el de mejor rendimiento con una *RECM* y *EAM* de 26,62 mm y 22,46 mm respectivamente. El último conjunto de modelos (del 13 al 16), con ingresos de p_{t-1} , IOS_{t-1} , IOS_{t-2} , TSM_{t-1} , TSM_{t-2} , ONI_{t-1} y ONI_{t-2} como predictoras se determinó que el modelo 16 es el mejor dentro de este conjunto, con un valor de *RECM* de 29.84 mm y *EAM* de 26.66 mm. Después de este análisis podemos concluir que el modelo No

12 es que mejor rendimiento tiene para esta zona. Este modelo fue realizado con una muestra ordenada y entrenada con una red GRNN.

En el Labrado el coeficiente de Nash- Sutcliffe (E) que más se acerca a la unidad es el modelo No 15 y en Chanlud es el modelo No 12 coincidiendo en ambas microcuencas con las medidas de error (EAM , $RECM$) más bajas.

En Conclusion, el modelo No 15 para la el Labrado y el No 12 para Chanlud son los seleccionados de cada conjunto de RNAs porque presentan los errores más bajos y reflejan un mejor comportamiento hidrológico (*coeficiente E*).

3.6.3. Modelo ARIMA seleccionado

Entre tanto el modelo ARIMA que mejor se ajustó al comportamiento de la lluvia en el Labrado es el $ARIMA(1,0,0)(1,0,1)$ y para la microcuenca Chanlud el $ARIMA(0,0,0)(0,1,1)$.

Tabla 16.- Ajustes del Modelo ARIMA para la microcuenca El Labrado

Ajuste del modelo $ARIMA(1,0,0)(1,0,1)$										
Estadístico de ajuste	Media	Mínimo	Máximo	Percentil						
				5	10	25	50	75	90	95
RECM(mm)	41.546	41.546	41.546	41.546	41.546	41.546	41.546	41.546	41.546	41.546
EAM(mm)	31.827	31.827	31.827	31.827	31.827	31.827	31.827	31.827	31.827	31.827

Tabla 17.- Ajustes del Modelo ARIMA para la microcuenca Chanlud

Ajuste del modelo $ARIMA(0,0,0)(0,1,1)$										
Estadístico de ajuste	Media	Mínimo	Máximo	Percentil						
				5	10	25	50	75	90	95
RECM(mm)	50.617	50.617	50.617	50.617	50.617	50.617	50.617	50.617	50.617	50.617
EAM(mm)	33.828	33.828	33.828	33.828	33.828	33.828	33.828	33.828	33.828	33.828

En la tabla 16 y 17 se presentan los ajustes estadísticos del modelo para cada microcuenca, como se puede observar el modelo seleccionado mantiene constantes

los estadísticos de ajuste. El coeficiente E para el modelo ARIMA del Labrado es de 0.145 y para Chanlud el valor de E es de 0.156.

3.6.4. Determinación del mejor modelo entre la RNAs y el ARIMA

En la tabla 18 se presentan la comparación de los estimadores de predicción para la RNA y el modelo ARIMA seleccionado.

Tabla 18.- Comparación en función de los errores entre el modelo ARIMA y la RNAs

	Modelo	RECM(mm)	EAM(mm)	Coeficiente E
El Labrado				
1	RNAs de tipo GRNN	32.22	24.74	0.490
2	ARIMA (1.0.0) (1,0,1)	41.54	31.82	0.145
Chanlud				
1	RNAs de tipo GRNN	29.62	22.46	0.630
2	ARIMA (0,0,0)(0,1,1)	50,61	33.82	0.156

Se puede observar en la tabla 18, que de igual manera para ambas microcuencas la RNA tienen un mejor rendimiento en comparación con el modelo ARIMA y por consiguiente son los modelos seleccionados para la predicción de la serie de lluvia.

3.6.5. Predicción de la lluvia

Con el mejor modelo para cada microcuenca; vamos a predecir una serie de tiempo que nos servirá para el pronóstico del caudal en el siguiente capítulo. Para no saturar de información se graficará los últimos años de la predicción; tanto de El Labrado como de El Chanlud (Figura 11 y 12).

Figura 11.- Predicciones de la lluvia en la microcuenca El Labrado





Figura 12.- Predicciones de la lluvia en la microcuenca Chanlud





CAPITULO IV:

PREDICCION DEL CAUDAL

4. Predicción del caudal

4.1. Introducción

En este capítulo se va a pronosticar el caudal a la salida de las dos microcuencas de estudio, para lo cual se aplicaron dos metodologías. El primer método es a través del entrenamiento de las RNAs que mejor se adapte al conjunto de datos utilizados y el segundo método es un híbrido que resulta de la unión del modelo ARIMA y una RNA. Luego se comparó los resultados de estos dos métodos, y se seleccionó el mejor.

Los caudales que se utilizaron fueron obtenidos a través de un balance hídrico realizado por el Consejo de la Cuenca del río Machángara en un estudio Hidrológico de la cuenca del río Machángara (sus valores se presentan en el anexo 2 y 3).

4.2. Modelo de RNAs

Las RNAs se realizaron en el programa NeuralTools 6.3. De igual manera se plantearon diferentes tipos de modelos (Tabla 19) para la predicción del caudal mensual de un determinado mes (Qm_t). Con variables de entrada para el entrenamiento y validación de las redes como: lluvia actual (p_t), lluvia del mes anterior (p_{t-1}), lluvia de dos meses anteriores (p_{t-2}) y caudal de uno y dos meses anteriores (c_{t-1} , c_{t-2}). La lluvia utilizada para este procedimiento en cada zona, fue la obtenida en el capítulo anterior.

Para la selección de la red que mejor se adapta al conjunto de información nos vamos a basar en la *RECM*, *EAM* y el coeficiente *E*.

Tabla 19.- Modelos para la predicción el caudal mensual (Q_m) en RNAs

Modelo	Tipo	Muestra	Variables de entrada
1	MLF	Aleatoria	$Q_{m_t}=f(p_t)$
2	GRNN	Aleatoria	$Q_{m_t}=f(p_t)$
3	MLF	Ordenada	$Q_{m_t}=f(p_t)$
4	GRNN	Ordenada	$Q_{m_t}=f(p_t)$
5	MLF	Aleatoria	$Q_{m_t}=f(p_t, c_{t-1})$
6	GRNN	Aleatoria	$Q_{m_t}=f(p_t, c_{t-1})$
7	MLF	Ordenada	$Q_{m_t}=f(p_t, c_{t-1})$
8	GRNN	Ordenada	$Q_{m_t}=f(p_t, c_{t-1})$
9	MLF	Aleatoria	$Q_{m_t}=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$
10	GRNN	Aleatoria	$Q_{m_t}=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$
11	MLF	Ordenada	$Q_{m_t}=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$
12	GRNN	Ordenada	$Q_{m_t}=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$
13	MLF	Aleatoria	$Q_{m_t}=f(p_{t-1})$
14	GRNN	Aleatoria	$Q_{m_t}=f(p_{t-1})$
15	MLF	Ordenada	$Q_{m_t}=f(p_{t-1})$
16	GRNN	Ordenada	$Q_{m_t}=f(p_{t-1})$
17	MLF	Aleatoria	$Q_{m_t}=f(p_{t-1}, c_{t-1})$
18	GRNN	Aleatoria	$Q_{m_t}=f(p_{t-1}, c_{t-1})$
19	MLF	Ordenada	$Q_{m_t}=f(p_{t-1}, c_{t-1})$
20	GRNN	Ordenada	$Q_{m_t}=f(p_{t-1}, c_{t-1})$
21	MLF	Aleatoria	$Q_{m_t}=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$
22	GRNN	Aleatoria	$Q_{m_t}=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$
23	MLF	Ordenada	$Q_{m_t}=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$
24	GRNN	Ordenada	$Q_{m_t}=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$

4.3. Modelo Híbrido

Para este modelo nos basamos en un estudio “Drought Forecasting Using a Hybrid Stochastic and Neural Network Model”, realizado por Mishra et al. (2007), que utilizó un modelo híbrido para la predicción de la sequía en un área de 4,265 km² del río Kansabati ubicado en la India. Mishra et al. (2007) combinó un modelo estocástico (ARIMA) con el modelo de RNAs. En un principio se determinó el índice de precipitación estandarizado (SPI) para incluir en la modelación ARIMA y los residuales que se obtuvieron lo utilizaron en las RNAs. La ecuación de la predicción para este modelo híbrido viene dado por:

$$Y_t = L_t + N_t$$

Ecuación 8

Dónde:

Y_t = valor a predecir

L_t = valor determinado en el modelo ARIMA

N_t = Valor determinado en el modelo RNAs (residuo)

La ecuación 8 se utilizó en este estudio; sin embargo para el modelamiento de la red híbrida (Y_t), se utilizó el índice de caudales estandarizados en lugar del SPI, debido a que se quiere determinar el caudal.

4.3.1. Estimación del índice de caudales estandarizados

Para la estimación de este índice; primero ajustamos los caudales a una distribución normal. Existen varias transformaciones que se pueden efectuar para asegurar que la variable x se asemeje a una distribución normal. Entre las transformaciones que se manejan son: la variable elevada a una potencia, logaritmos, raíz cuadrada de la variable, etc.

La selección de la mejor transformación a una distribución normal se verifica a través de una prueba de bondad de ajuste. La prueba seleccionada es la chi cuadrado (χ^2) que viene dado por la siguiente formula:

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad \text{Ecuación 9}$$

$$E_i = nP_i$$

Dónde:

O_i = número de datos observados en la clase i

E_i = número de datos en la clase esperada

n = número de datos

P_i = probabilidad asignada a cada clase

De todas las transformaciones la que mejor ajuste tiene es la que tenga el menor valor de χ^2 (Tukey, 1977).

Se utilizó el comando “Ladder” en software STATA. Este comando evalúa de una manera rápida las alternativas de transformación de una variable para ajustarla a una distribución normal. La mejor transformación se aplicó a todo el conjunto de datos del caudal.

El siguiente paso fue la estandarización del conjunto de datos normalizados; para ello se aplicó la siguiente formula:

$$Y1 = \frac{x1 - \bar{X}}{G} \quad \text{Ecuación 10}$$

Dónde:

$Y1$ = valor estandarizado

$X1$ = valor a estandarizar

\bar{X} = media de los valores a estandarizar

G = desviación estándar de los valores a estandarizar

4.3.2. Determinación del valor L_t con el modelo ARIMA

Con los caudales normalizados y estandarizados, el siguiente paso es determinar la parte L_t de la ecuación 8 del modelo híbrido a través de modelo ARIMA. El modelamiento se lo realizó en el software IBM SPSS Statistics 20.0, y así obtuvimos los valores del índice de caudal estandarizado pronosticado (L_t). Sin embargo, también necesitamos los residuales de esta predicción (diferencia entre el caudal observado y el caudal pronosticado), que sirvió como entrada para la determinación de la segunda parte (N_t) de la ecuación 8.

4.3.3. Determinación del valor N_t con el modelo de RNAs

En el estudio de Mishra et al., 2007, se realizó un entrenamiento de las RNAs con la información de los residuales de los períodos anteriores al período deseado. En nuestra investigación, los residuales del modelo ARIMA, se entrenaron y validaron conjuntamente con la precipitación en cada microcuenca. Se plantearon 2 prototipos con diferentes variables de entrada como: el residual del índice de caudal estandarizado del mes anterior ($RICE_{t-1}$) y la precipitación de mes anterior (p_{t-1}) y se trabajó con dos muestras (ordenada y aleatoria) y con los dos tipos de redes que

presenta este programa (MLF y PN/GRNN); es decir se obtuvieron 8 modelos (Tabla 20) y se seleccionó el de mejor rendimiento, utilizando la RECM y EAM.

Tabla 20.-Modelos para la predicción del $RICE_t$ en RNAs

Modelo	Tipo de red	Muestra	Predictoras
1	MLF	Aleatoria	$RICE_t = f(p_{t-1})$
2	GRNN	Aleatoria	$RICE_t = f(p_{t-1})$
3	MLF	Ordenada	$RICE_t = f(p_{t-1})$
4	GRNN	Ordenada	$RICE_t = f(p_{t-1})$
5	MLF	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$
6	GRNN	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$
7	MLF	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$
8	GRNN	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$

4.3.4. Predicción de caudal con el modelo híbrido

Se sumaron las dos partes de la ecuación 8 (L_t y N_t) y así encontramos el índice de caudal estandarizado. Para convertirlo en caudal, primero con la ecuación 11 calculamos $X1$, luego con este valor se invirtió el proceso del que se utilizó para transformarla a una distribución normal, obteniendo así el valor del caudal requerido.

La ecuación para calcular $X1$ queda así:

$$x1 = Y1G + \overline{X} \quad \text{Ecuación 11}$$

4.4. Evaluación de los modelos

Luego de tener los 2 modelos planteados para la predicción del caudal (RNA, modelo Híbrido), lo comparamos a través de la RECM y del coeficiente de eficiencia de Nash-Sutcliffe (E); así obtuvimos el modelo con el mejor rendimiento para la predicción del caudal en las dos mocrocuencias.

4.5. Resultados

4.5.1. Selección de Modelo de RNAs

Los 24 modelos propuestos para la selección de la mejor red para cada microcuenca se presentan en la tabla 21 y 22 con sus respectivos valores *RECM*, *EAM* y *coeficiente E*.

Tabla 21.- Evaluación de los modelos de predicción de caudales con RNAs en El Labrado

Modelo	Tipo	Muestra	Variables de entrada	RECM (m ³ /seg)	EAM (m ³ /seg)	Coeficiente E
1	MLF	Aleatoria	$Qm_t=f(p_t)$	0.673	0.535	0.158
2	GRNN	Aleatoria	$Qm_t=f(p_t)$	0.674	0.540	0.235
3	MLF	Ordenada	$Qm_t=f(p_t)$	0.653	0.525	0.284
4	GRNN	Ordenada	$Qm_t=f(p_t)$	0.654	0.526	0.291
5	MLF	Aleatoria	$Qm_t=f(p_t, c_{t-1})$	0.648	0.523	0.196
6	GRNN	Aleatoria	$Qm_t=f(p_t, c_{t-1})$	0.649	0.519	0.221
7	MLF	Ordenada	$Qm_t=f(p_t, c_{t-1})$	0.624	0.506	0.306
8	GRNN	Ordenada	$Qm_t=f(p_t, c_{t-1})$	0.633	0.509	0.305
9	MLF	Aleatoria	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	0.637	0.509	0.046
10	GRNN	Aleatoria	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	0.638	0.508	0.211
11	MLF	Ordenada	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	0.612	0.490	0.226
12	GRNN	Ordenada	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	0.632	0.508	0.309
13	MLF	Aleatoria	$Qm_t=f(p_{t-1})$	0.712	0.580	0.040
14	GRNN	Aleatoria	$Qm_t=f(p_{t-1})$	0.719	0.582	0.015
15	MLF	Ordenada	$Qm_t=f(p_{t-1})$	0.674	0.549	0.123
16	GRNN	Ordenada	$Qm_t=f(p_{t-1})$	0.680	0.552	0.053
17	MLF	Aleatoria	$Qm_t=f(p_{t-1}, c_{t-1})$	0.663	0.532	0.052
18	GRNN	Aleatoria	$Qm_t=f(p_{t-1}, c_{t-1})$	0.671	0.534	0.118
19	MLF	Ordenada	$Qm_t=f(p_{t-1}, c_{t-1})$	0.635	0.512	0.218
20	GRNN	Ordenada	$Qm_t=f(p_{t-1}, c_{t-1})$	0.623	0.504	0.158
21	MLF	Aleatoria	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.652	0.518	0.009
22	GRNN	Aleatoria	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.663	0.522	0.108
23	MLF	Ordenada	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.625	0.510	0.111
24	GRNN	Ordenada	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.599	0.481	0.142

Tabla 22.- Evaluación de los modelos de predicción de los caudales con RNAs en la zona el Chanlud

Modelo	Tipo	Muestra	Variables de entrada	RECM (m ³ /seg)	EAM (m ³ /seg)	Coeficiente E
1	MLF	Aleatoria	$Qm_t=f(p_t)$	1.297	1.046	0.347
2	GRNN	Aleatoria	$Qm_t=f(p_t)$	1.312	1.060	0.331
3	MLF	Ordenada	$Qm_t=f(p_t)$	1.298	1.053	0.367
4	GRNN	Ordenada	$Qm_t=f(p_t)$	1.317	1.076	0.348
5	MLF	Aleatoria	$Qm_t=f(p_t, c_{t-1})$	1.203	0.961	0.438
6	GRNN	Aleatoria	$Qm_t=f(p_t, c_{t-1})$	1.241	1.001	0.402
7	MLF	Ordenada	$Qm_t=f(p_t, c_{t-1})$	1.211	1.004	0.448
8	GRNN	Ordenada	$Qm_t=f(p_t, c_{t-1})$	1.229	1.011	0.432
9	MLF	Aleatoria	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	1.187	0.946	0.452
10	GRNN	Aleatoria	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	1.240	0.999	0.403
11	MLF	Ordenada	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	1.152	0.928	0.501
12	GRNN	Ordenada	$Qm_t=f(p_t, p_{t-1}, c_{t-1}, c_{t-2})$	1.044	0.822	0.590
13	MLF	Aleatoria	$Qm_t=f(p_{t-1})$	0.632	0.509	0.351
14	GRNN	Aleatoria	$Qm_t=f(p_{t-1})$	0.640	0.517	0.334
15	MLF	Ordenada	$Qm_t=f(p_{t-1})$	0.649	0.525	0.348
16	GRNN	Ordenada	$Qm_t=f(p_{t-1})$	0.658	0.536	0.330
17	MLF	Aleatoria	$Qm_t=f(p_{t-1}, c_{t-1})$	0.603	0.486	0.410
18	GRNN	Aleatoria	$Qm_t=f(p_{t-1}, c_{t-1})$	0.605	0.492	0.405
19	MLF	Ordenada	$Qm_t=f(p_{t-1}, c_{t-1})$	0.615	0.507	0.415
20	GRNN	Ordenada	$Qm_t=f(p_{t-1}, c_{t-1})$	0.630	0.517	0.386
21	MLF	Aleatoria	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.567	0.451	0.477
22	GRNN	Aleatoria	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.558	0.448	0.495
23	MLF	Ordenada	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.584	0.468	0.472
24	GRNN	Ordenada	$Qm_t=f(p_{t-1}, p_{t-2}, c_{t-1}, c_{t-2})$	0.566	0.451	0.505

En las dos tablas anteriores; los primeros doce modelos se entrenaron incluyendo la lluvia pronosticada del mes que se quiere predecir el caudal (p_t) y los siguientes doce modelos no incluyen la variable p_t .

En la Tabla 21, donde se encuentran los resultados del Labrado, podemos ver que la *RECM* disminuye desde un 0,719 mm en el modelo 14 a un valor de 0.599 mm en el modelo 24; mientras que el valor del *EAM* desciende desde un 0,582 mm (modelo 14) a 0.481mm (modelo 24). El menor coeficiente *E* corresponde al modelo 21 con un 0.009 y el mayor en el modelo 12 con un valor de 0.309. En términos del *EAM* y de la

RECM, el modelo 24 presenta un mejor rendimiento; sin embargo el modelo que presentan un coeficiente E más cercano a la unidad es el modelo 12.

En Chanlud (tabla 22); el valor más alto de la *RECM* corresponde al modelo 4 con un valor de 1.317 mm y llega a disminuir a 0.558 mm (modelo 22). EL valor del *EAM* más alto está en el modelo 4 y el valor más bajo tiene el modelo 22 con 1.076 mm y 0.448mm respectivamente. El coeficiente E más bajo se encuentra en el modelo 16 con un valor de 0.330 y el mejor está en el modelo 12 con un valor de 0.590. En términos de *EAM* y de la *RECM* el modelo 22 presenta mejor rendimiento; sin embargo el modelo 12 tiene un coeficiente E más cercano a la unidad.

Luego de presentar los resultados en ambas microcuencas y al no coincidir los tres los tres factores estadísticos de predicción en un mismo modelo, tenemos que tomar la decisión de quien tiene mayor peso sí las medidas de error (*RECM*, *EAM*) o el coeficiente Nash- Sutcliffe en la selección del modelo para cada microcuenca.

El coeficiente Nash- Sutcliffe (E) es el que sobresale en comparación de las medidas de error debido a que este coeficiente es muy utilizado exclusivamente en la evaluación de modelos hidrológicos y por esta razón los modelos 12 (Figura 13 y 14) son los seleccionados para el Labrado y Chanlud.

Figura 13.- Gráfica del modelo 12 en la microcuenca El Labrado





Figura 14.- Gráfica del modelo 12 en la microcuenca Chanlud



4.5.2. Modelo Híbrido realizado

4.5.2.1. Índices de caudales estandarizados obtenidos

La mejor alternativa de transformación de una variable para ajustarla a una distribución normal fue usar la raíz cuadrada con valores de $\chi^2 = 14.20$ en El Labrado y de 8.09 en Chanlud (Tabla 23 y 24).

Tabla 23.- Determinación de la mejor alternativa para ajustarla a una distribución normal con datos de caudal de EL Labrado

Transformación	Formula	χ^2
Idéntica	Qm	41.35
Raíz Cuadrada	\sqrt{Qm}	14.2
Logaritmo	$\log Qm$	26.11

Figura 15.- Grafica de diferentes transformaciones del caudal del Labrado para ajustarla a una distribución normal

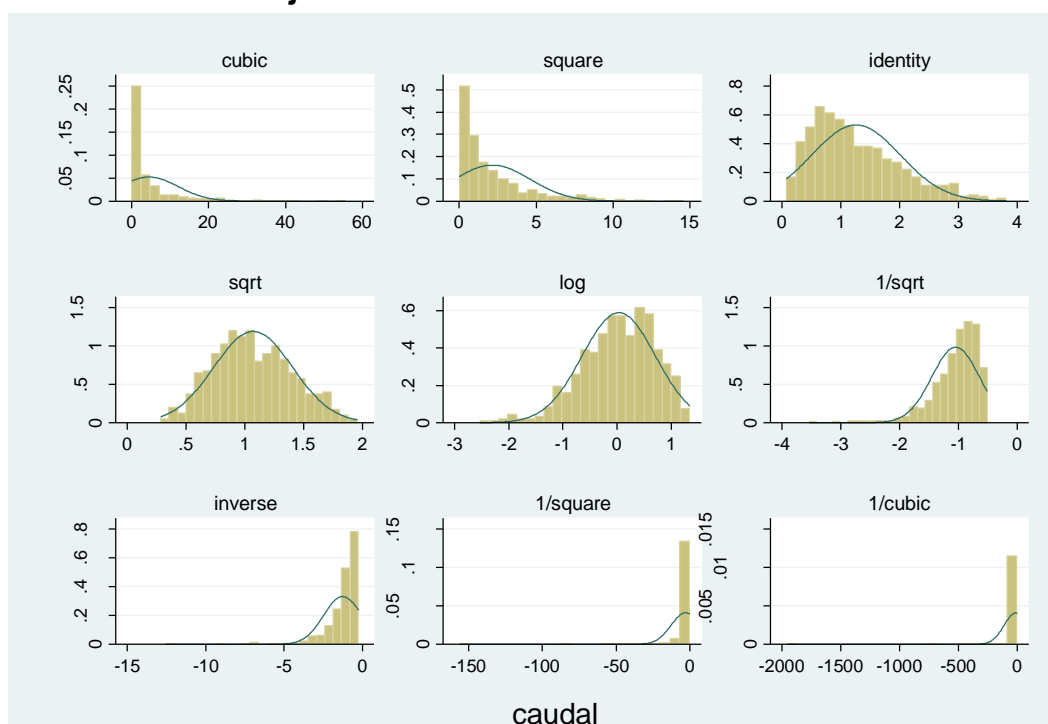
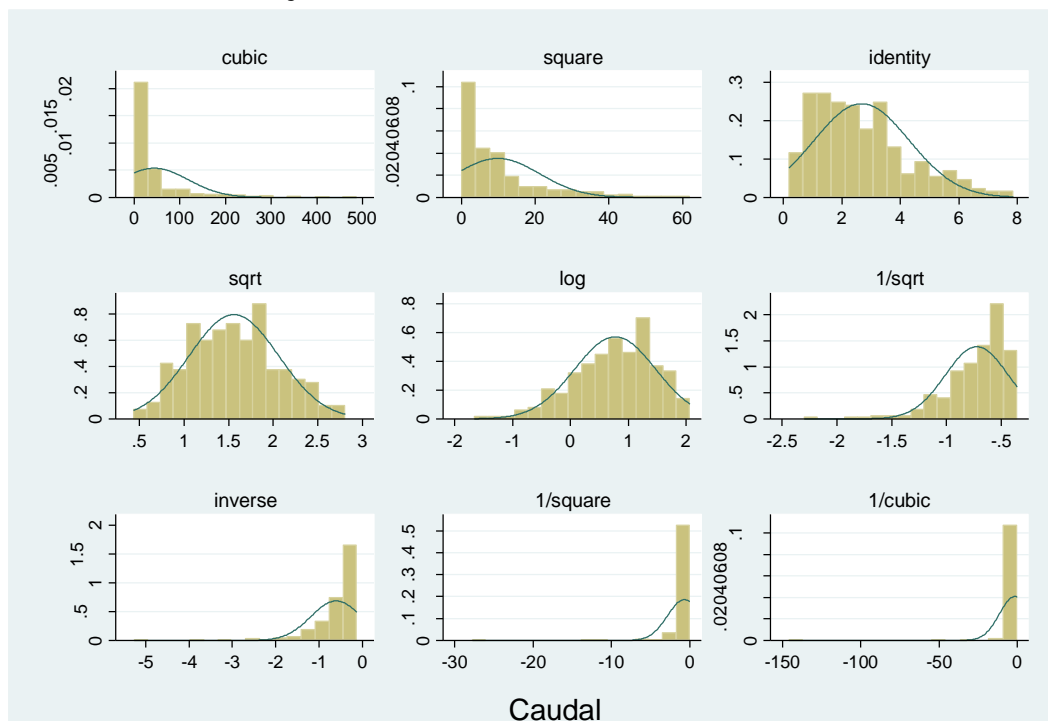


Tabla 24.- Determinación de la mejor alternativa para ajustarla a una distribución normal con datos de caudal de Chanlud

Transformación	Formula	χ^2
Idéntica	Qm	20.75
Raíz Cuadrada	\sqrt{Qm}	8.09
logaritmo	$\log Qm$	12.5

Figura 16.-Grafica de diferentes transformaciones del caudal del Chanlud para ajustarla a una distribución normal



Esta transformación (\sqrt{Qm}), se realizó a toda la serie de caudales en cada microcuenca; para luego utilizar la ecuación 10 de estandarización y obtener los índices de caudales estandarizados (ICE), que son las entradas para el modelo híbrido.

La tabla 25, contienen los valores de las variables utilizadas en la ecuación 10.

Tabla 25.- Valor de variables a utilizar para cada microcuenca

	EL Labrado	Chanlud
desviación estándar (m ³ /seg)	0.3361	0.4994
media (m ³ /seg)	1.0688	1.5577

4.5.2.2. Valor L_t determinado

Esta es la primera parte de la ecuación 8 del modelo híbrido y como se explicó en la metodología esta parte se determina a través de un modelo ARIMA. En la tabla 26 se puede observar el modelo ARIMA seleccionado de cada microcuenca.

Tabla 26.- Modelo ARIMA para cada zona

	Tipo de modelo ARIMA
El Labrado	ARIMA (1,0,0)(1,0,1)
Chanlud	ARIMA (0,0,0)(0,1,1)

4.5.2.3. Valor N_t determinado

Con los residuales obtenidos en el modelo ARIMA de cada zona; se le entrenó en las RNAs con los 8 modelos para cada microcuenca. La RECM y el EAM se describen en la Tabla 27 y 28, estos parámetros nos servirán para la selección del modelo que mejor describe el residual de índice de caudal estandarizado ($RICE_t$).

Tabla 27.- Errores en la predicción $RICE_t$ en cada modelo de RNA en Chanlud

Modelo	Tipo de red	Muestra		RECM(m ³ /seg)	EAM (m ³ /seg)
1	MLF	Aleatoria	$RICE_t = f(p_{t-1})$	0.7923	0.6353
2	GRNN	Aleatoria	$RICE_t = f(p_{t-1})$	0.8110	0.6522
3	MLF	Ordenada	$RICE_t = f(p_{t-1})$	0.8062	0.6481
4	GRNN	Ordenada	$RICE_t = f(p_{t-1})$	0.8215	0.6561
5	MLF	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.7550	0.5957
6	GRNN	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.7723	0.6247
7	MLF	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.7667	0.6061
8	GRNN	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.7566	0.5959

Tabla 28.-Errores en la predicción $RICE_t$ para cada modelo de RNA en El Labrado

Modelo	Tipo de red	Muestra	Predictoras	RECM (mm)	EAM (mm)
1	MLF	Aleatoria	$RICE_t = f(p_{t-1})$	0.4588	0.3598
2	GRNN	Aleatoria	$RICE_t = f(p_{t-1})$	0.4595	0.3574
3	MLF	Ordenada	$RICE_t = f(p_{t-1})$	0.4379	0.3430
4	GRNN	Ordenada	$RICE_t = f(p_{t-1})$	0.4384	0.3433
5	MLF	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.4454	0.3481
6	GRNN	Aleatoria	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.4246	0.3301
7	MLF	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.4264	0.3335
8	GRNN	Ordenada	$RICE_t = f(p_{t-1}, RICE_{t-1})$	0.3917	0.2987

En la microcuenca Chanlud podemos observar que el modelo 5 tiene los valores más bajos de la RECM y EAM (0.7550 m³/seg y 0.5957 m³/seg respectivamente) y en

conclusión es el modelo seleccionado para la predicción del residual de índice de caudal estandarizado que es la segunda parte (N_t) de la ecuación 8. Este modelo 5, fue realizado con una muestra aleatoria con valores de la precipitación y el residual del índice de caudal estandarizado de un mes anterior, además fue entrenado en una red MLF.

En el Labrado, el modelo que va a servir para la predicción del N_t es el No 8, cuyo entrenamiento se realizó con la red GRNN, utilizando una muestra ordenada, y sus variables de entrada fueron la precipitación y el residual del índice del caudal estandarizado de un mes anterior al deseado. El valor de la *RECM* es de 0.3917 m³/seg y el *EAM* de 0.2987 m³/seg.

Con estos dos modelos se realizó la predicción del residual del Índice de caudal estandarizado para luego sumar las dos partes del modelo Híbrido

4.5.2.4. Sumatoria de los dos componentes (L_t y N_t) del modelo híbrido

Se realizó la sumatoria de ambos componentes y así se pudo predecir el índice de caudal estandarizado. La Figura 17 y 18 presentan las predicciones del caudal conjuntamente con el caudal observado luego de las respectivas transformaciones inversas para pasar a m³/seg. Donde podemos ver que en la microcuenca el Labrado no existe mucha variación en la predicción porque coeficiente *E* es de 0.797 a comparación del Chanlud que tiene un valor de 0.404 (predicción perfecta $E=1$). También se puede observar que los mayores errores en las predicciones se presentan en los picos altos.

Figura 17.- Predicción del caudal con el modelo híbrido para la microcuenca El Labrado





Figura 18.- Predicción del caudal con el modelo híbrido para la microcuenca Chanlud



4.5.3. Selección del mejor modelo para la predicción del caudal

Luego de la presentación de los dos modelos (RNAs, Modelo Híbrido) para el pronóstico del caudal en ambas microcuencas; podemos concluir en función de la *RECM* y del coeficiente *E* (Tabla 29) que el modelo híbrido (Figura 17) es el que mejor se adapta a los datos del Labrado con un valor de 0.33 m³/seg y 0,797 respectivamente. En el Chanlud sobresale el modelo de RNAs (Figura 14) con un valor de *RECM* 1.04 m³/seg y un coeficiente *E* de 0.590.

Tabla 29.- Selección del modelo de predicción a través de la RECM

Embalse	Modelos	<i>RECM</i>	<i>Coeficiente E</i>
El Labrado	Modelo de RNAs	0.63	0.309
	Modelo Híbrido	0.33	0.797
El Chanlud	Modelo de RNAs	1.044	0.590
	Modelo Híbrido	1.25	0.404



Capítulo V

Conclusiones y Recomendaciones

5. Conclusiones y recomendaciones

5.1. Sobre el Análisis de la precipitación

Se ha logrado determinar una relación entre la lluvia de cada microcuenca con los índices y variables de tipo regional y/o global que son obtenidos en la parte occidental de nuestras áreas de estudio (Océano Pacífico). Si bien las correlaciones no son altas de los predictores seleccionados (TSM, ONI, IOS); pero tampoco son producto de una relación al azar como se pudo determinar con la prueba t Student.

La TSM tiene la mejor relación con la lluvia en ambas microcuencas con 0.312 en el Labrado y 0.209 en el Chanlud con un 99% de certeza de que no provienen de una relación producto del azar. El ONI y IOS también influyen en la cantidad de la lluvia en la zona de estudio; aunque sus relaciones son menores comparados a la TSM; pero sus vínculos con la lluvia tienen el 99% y 95% respectivamente de certeza de que no provienen del azar.

La determinación de las correlaciones permite contribuir a las investigaciones en las partes altas de la cuenca referente a los efectos que pueden tener las variables e índices climáticos sobre la lluvia de la zona; debido a que ambas microcuencas en estudio son de la parte alta de cuenca Machángara.

5.2. Sobre la predicción de la precipitación

Se presentó 2 modelos para cada microcuenca (ARIMA y RNAs) y se seleccionó al mejor modelo a través de los parámetros estadísticos (EAM, RECM y el coeficiente E). Los modelos de RNAs fueron las mejores en comparación a los modelos ARIMA en las dos microcuencas.

Se ha logrado presentar una metodología para la predicción de la lluvia con el ingreso de los predictores determinados en capítulo 2 y la lluvia observada en cada microcuenca. En el Labrado, cuando se quiere predecir para un determinado mes; el modelo es una red de regresión generalizada, que debe recibir la siguiente información: ONI, TSM y IOS de uno y dos meses anteriores y la precipitación de un mes anterior.

Mientras que para Chanlud el modelo seleccionado se fundamenta en una red de regresión generalizada y recibe como variables de entrada para la predicción de un determinado mes a la TSM de uno y dos meses anteriores, además del ONI, IOS y lluvia de un mes anterior.

Como se utilizaron los tres predictores y la lluvia de cada microcuenca en el entrenamiento de cada red neuronal, existía la probabilidad de que la red entrenada solo tome información de la lluvia para calibrar a la red. Sin embargo el impacto de variables demuestra que 14 de los 16 modelos entrenados en el Labrado y 8 modelos en la microcuenca Chanlud reciben mayor información de la temperatura superficial del mar; cumpliendo con el objetivo de utilizar los predictores climáticos para la predicción.

5.3. Sobre la predicción de los caudales

De igual manera se continuó con el mismo esquema de la investigación; siguiendo con las RNAs; pero se incluyó el modelo híbrido que combina el modelo ARIMA y las RNAs. Comparando ambos modelos sobresale el modelo Híbrido en el Labrado; con valores de coeficiente de Nash-Sutcliffe (E) de 0.797 en comparación con el otro modelo ($E=0.309$). En Chanlud, el modelo seleccionado fue el de la RNA con un valor de E igual a 0.590 comparado al modelo híbrido ($E=0.404$).

En el Labrado cuando se quiere predecir el caudal; el modelo híbrido está formado por un modelo ARIMA (1,0,0)(1, 0,1) y una RNA de tipo GRNN que recibe como variables de entrada a la lluvia y al residual de índice de caudal estandarizado de un mes anterior. Para la microcuenca Chanlud cuando se va a predecir el caudal, el modelo de RNA es de tipo GRNN, que recibe la siguiente información: lluvia y caudal de uno y dos meses anteriores.

Sin ninguna duda las redes neuronales artificiales son una herramienta muy importante para este tipo de trabajos porque encuentran rápidamente relaciones entre las variables de entrada para así mejorar la predicción de un evento.

En conclusion, el modelo para la predicción del caudal para cada microcuenca ayudará a todos los actores involucrados en este lugar, como lo son la hidroeléctrica, la planta de potabilización, canales de riego; los cuales podría conocer de una manera más específica la cantidad de agua que pueden tener en un determinado mes.

5.4. Recomendaciones

La cuenca del Machángara es de vital importancia para la ciudad de Cuenca y más aun considerando que dentro de pocos años el 70% de agua potable para el cantón Cuenca dependerá de ella. Por esta razón se debe realizar investigaciones de modelos que sean mucho más eficientes, como es el caso de los modelos híbridos, debido a que combinan las ventajas de cada modelo presente; para que así los actores de esta cuenca puedan tomar mejores acciones en beneficio de la población.

También se debe buscar variables o índices climáticos que mejoren la relación con la lluvia de las dos microcuencas incluyendo información climática de la parte oriental (Océano Atlántico).

Bibliografía

1. Aguilar, R. "Red Neuronal de Topología Flexible". En: VI Congreso Nacional de Ciencias de la Computación, La Paz, Bolivia. Septiembre de 1999.
2. Arntz, W.; Fahrbach, E. 1996. El Niño, experimento climático de la naturaleza. Fondo de Cultura Económica, pp. 309.
3. Ashok, K., Behera, S.K., Rao, S.A., Weng, H., Yamagata, T., 2007. El Niño Modoki and its possible teleconnection. *Journal of Geophysical Research: Oceans* (1978–2012) 112.
4. Ballarin, V.L., Meschino, G.J., Abras, G.N., Passoni, L.I., 2005. Segmentación de imágenes cerebrales de Resonancia Magnética basada en Redes Neuronales de Regresión Generalizada. *biológica* 14, 17.
5. Bertona, L., 2005. Entrenamiento de redes neuronales basado en algoritmos evolutivos
6. Campozano, L., 2011. Análisis de la robustez de un modelo de redes neuronales para la predicción de caudales en la cuenca alta del río Paute, Cuenca-Ecuador, Tesis de maestría.
7. Carvajal Escobar, Y., Correa, G.A., Muñoz, F.M., 2011. Modelos de predicción de caudal utilizando variables macroclimáticas y técnicas estadísticas multivariadas en el Valle Del Río Cauca.
8. Casimiro, G., Pilar, M., 2009. Técnicas de predicción económica. *Economía Aplicada III*, UPV/EHU.
9. Centros Radial K-medias [WWW Document], 2012. URL <http://www.lab.inf.uc3m.es/~a0080630/redes-de-neuronas/base-radial.html> (accessed 12.8.14).
10. Climate Explorer: About the Climate Explorer [WWW Document], n.d. URL <http://climexp.knmi.nl/about.cgi?id=someone@somewhere> (accessed 8.22.14).
11. Climate Prediction Center - Who We Are [WWW Document], n.d. URL http://www.cpc.ncep.noaa.gov/information/who_we_are/index.shtml (accessed 8.13.14).
12. Chávez Quisbert, N., 1997. MODELOS ARIMA. *Revista Ciencia y Cultura* 23–30.

13. De La Casa, A.C., Nasello, O. b, 2012. CAPACIDAD PREDICTIVA DEL NIÑO-OSCILACIÓN SUR (ENSO) Y DE OTROS INDICADORES CLIMÁTICOS SOBRE LA PRECIPITACIÓN EN CÓRDOBA, ARGENTINA. ANALES AFA 22.
14. De La Fuente, S., sf. Series Temporales: Modelo Arima
15. Díaz, P., Fernández, P., 2001. Determinación del tamaño muestral para calcular la significación del coeficiente de correlación lineal. Metodología de la Investigación 1, 6.
16. ElecAustro [WWW Document], n.d. URL <http://www.elecaustro.com.ec/index.php?seccion=U9zxH4J> (accessed 7.22.14).
17. García, R., 2005. Redes Neuronales Artificiales en Ingeniería Hidráulica y Medio ambiental: FUNDAMENTOS
18. Gutiérrez, P., Vázquez, J., Hernández, M., Ríos, A., 2013. Aplicación de la Red Neuronal Probabilística para la clasificación de productos conforme a sus especificaciones
19. Heredia Calderon, E., Loza, R.P., 1999. Influencia del ENSO Sobre los Caudales Mensuales de las Grandes Cuencas Hidrograficas del Ecuador, in: Hydrological and Geochemical Processes in Large Scale River Basins Conference, Manaus, Brazil, Amazon Basin Project (HiBAM), University of Brasilia. pp. 15–19.
20. IBM Knowledge Center, ¿Qué es una red neuronal?, 2013. URL http://www01.ibm.com/support/knowledgecenter/SSLVMB_21.0.0/com.ibm.spss.statistics.help/nnet_whatish.htm?lang=es (accessed 11.19.14).
21. Instituto Nacional de Meteorología e Hidrología, Red de estaciones Meteorológicas, n.d. Instituto Nacional de Meteorología e Hidrología.
22. Izaurieta, F., Saavedra, C., 2003. Redes neuronales artificiales. Artículo en línea]. Universidad de Concepción, Concepción, Chile. Disponible: <http://www.uta.cl/revistas/charlas/volumen16/Indice/Ch-csaavedra.pdf> [Consulta: 2003, 27 de septiembre].
23. Jiménez, R. 2008. Aspecto biológicos de El Niño en el Océano Pacífico Ecuatorial, pp. 309.
24. López, R.F., Fernández, J.M.F., 2008. Las Redes Neuronales Artificiales. Netbiblo.

25. Mishra, A.K., Desai, V.R., Singh, V.P., 2007. Drought forecasting using a hybrid stochastic and neural network model. *Journal of Hydrologic Engineering* 12, 626–638.
26. Mora, D.E., Willems, P., 2012. Decadal oscillations in rainfall and air temperature in the Paute River Basin—Southern Andes of Ecuador. *Theoretical and Applied Climatology* 108, 267–282.
27. Palisade. “Guía para el uso de NeuralTools: Programa auxiliar de redes neuronales para Microsoft® Excel Versión 5.7”. Ithaca, NY: Palisade Corporation, 2010. 110 p.
28. Pita Fernández, S., Pérttega Díaz, S., 1997. Relación entre variables cuantitativas. *Cad Aten Primaria* 4, 141–144.
29. Pinos Vargas, E., Espinoza, L., Román Arce, C., n.d. Pronóstico de caudales medios mensuales del río Caplina, aplicando redes neuronales artificiales (rna) y modelo autorregresivo periódico de primer orden par (1) Forecast for mean monthly discharge of the Caplina river, by applying artificial neural network (rna) and periodic.
30. Porras, S.T., Moreno, E.M., 2013. Modelos Neuronales Aplicados en Economía: Casos Prácticos mediante Mathematica / Neural Networks. Addlink Software Científico.
31. Poveda, G., 2004. La hidroclimatología de Colombia: una síntesis desde la escala inter-decanal hasta la escala diurna. *Rev. Acad. Colomb. Cienc* 28, 201–222.
32. Protección de Fuentes Hídricas - Consejo de la cuenca del Machángara [WWW Document], n.d. URL http://www.etapa.net.ec/DGA/dga_pro_fue_hid_con_cue_mac.aspx (accessed 7.17.14).
33. Puertas Orozco, O.L., Carvajal Escobar, Y., 2011. Incidencia de El Niño-Oscilación del Sur en la precipitación y la temperatura del aire en Colombia, utilizando el Climate Explorer. *Revista Científica Ingeniería y Desarrollo* 23, 104–118.

34. Ramirez B., V.H., Jaramillo R., A., 2009. Relación entre el índice oceánico de El Niño y la lluvia en la región andina central de Colombia.
35. Rodríguez, E., Torres, J., León, P., 2000. Pronóstico de la Precipitación Máxima en 24 horas en la Zona Cafetera.
36. Rossel, F., 1997, Influencia de El Niño sobre los regímenes hidro-pluviométricos del Ecuador, serie INSEQ No.18, tomos I, II y III, Publicación INAMHI-ORSTOM
37. Salas, J.D., Fu, C., Rajagopalan, B., 2010. Long-range forecasting of Colorado streamflows based on hydrologic, atmospheric, and oceanic data. *Journal of Hydrologic Engineering* 16, 508–520.
38. Salas, R., 2004. Redes Neuronales Artificiales. Universidad de Valparaíso. Departamento de Computación.
39. Socha, D., Ortiz, G., 2005. Aplicación de redes neuronales MLP a la predicción de un paso en series de tiempo
40. SPSS, 2011, SPSS for Windows, Chicago, Illinois, USA
41. Trouet, V., Van Oldenborgh, G.J., 2013. KNMI Climate Explorer: A Web-Based Research Tool for High-Resolution Paleoclimatology. *Tree-Ring Research* 69, 3–13. doi:10.3959/1536-1098-69.1.
42. Troup, A.J. 1965. The Southern Oscillation. *Q. J. Roy. Meteorol. Soc.* 91:490-506.
43. Tukey, J.W., 1977. *Exploratory data analysis*. Reading, Ma 231, 32.
44. Villavicencio Riera, V.E., Chávez Ochoa, L.M., 2011. Estudio arqueológico de las cuencas media y baja del río Machángara.
45. Wrlgth P., Wallace L, Mitchell T., Deser C. 1988. Correlation structure of the El Niño / Southern Oscillation phenomenon. *Journal of Climate*, 1,609-625
46. Zúñiga, A., Jordán, C., 2005. Pronóstico de caudales medios mensuales empleando Sistemas Neurofuzzy. *Revista Tecnológica - ESPOL* 18.

ANEXOS:

Anexo 1.- Datos de las variables macroclimáticas

Tiempo	IOS	NIÑO 1+2	NIÑO 3	NIÑO 3.4	PDO	TSM (°C)	ONI
Jan-64	-0.4	-0.45	0.5	0.86	0.01	24.15	1.3
Feb-64	0	-0.39	0.17	0.42	-0.21	25.08	1.1
Mar-64	1.1	-0.6	-0.37	-0.29	-0.87	25.3	0.6
Apr-65	1.1	-0.88	-0.66	-0.33	-1.03	24.61	0.1
May-64	0.2	-1.98	-1.07	-0.59	-1.91	21.93	-0.4
Jun-64	0.8	-1.51	-1.14	-0.75	-0.32	21.44	-0.6
Jul-64	0.6	-1.12	-0.84	-0.76	-0.51	20.25	-0.6
Aug-64	1.5	-1.31	-1.02	-0.6	-1.03	19.48	-0.6
Sep-64	1.3	-0.69	-0.8	-0.84	-0.68	19.67	-0.7
Oct-64	1.3	-0.65	-0.63	-0.88	-0.37	19.79	-0.8
Nov-64	0.2	-0.16	-0.82	-1.07	-0.8	20.88	-0.8
Dec-64	-0.3	-0.49	-1.12	-1.07	-1.52	21.83	-0.8
Jan-65	-0.4	-0.15	-0.64	-0.7	-1.24	24.22	-0.8
Feb-65	0.4	0.14	-0.2	-0.35	-1.16	26.17	-0.6
Mar-65	0.8	0.95	-0.16	-0.36	0.04	26.71	-0.3
Apr-65	-0.5	1.86	0.21	-0.07	0.62	27.01	0
May-65	0.2	2.3	0.96	0.55	-0.66	26.09	0.2
Jun-65	-0.6	2.24	0.92	0.74	-0.8	24.6	0.5
Jul-65	-1.8	2.15	1.03	0.95	-0.47	23.26	0.8
Aug-65	-0.7	1.68	1.26	1.29	0.2	22.54	1.2
Sep-65	-1.3	0.87	1.47	1.51	0.59	21.26	1.5
Oct-65	-0.9	1.18	1.46	1.67	-0.36	21.57	1.7
Nov-65	-1.5	1.02	1.62	1.71	-0.59	22.29	1.9
Dec-65	0.2	1.16	1.51	1.6	0.06	23.35	1.9
Jan-66	-1.3	0.73	1.33	1.37	-0.82	25.15	1.7
Feb-66	-0.2	0.16	0.78	0.97	-0.03	25.88	1.4
Mar-66	-0.9	-0.67	0.22	0.95	-1.29	25.35	1.1
Apr-66	-0.2	-0.61	0.24	0.67	0.06	24.26	0.9
May-66	-0.4	-0.87	-0.44	0.28	-0.53	22.92	0.6
Jun-66	0.3	-1.04	0.03	0.51	0.16	21.8	0.4
Jul-66	0.1	-0.44	0.25	0.55	0.26	20.85	0.3
Aug-66	0.6	-0.34	-0.15	0.13	-0.35	20.17	0.3
Sep-66	-0.2	-0.47	-0.25	0.21	-0.33	20.04	0.1
Oct-66	-0.1	-0.32	-0.11	0.11	-1.17	20.51	0

Nov-66	0	-0.04	-0.33	0.04	-1.15	21.03	-0.1
Dec-66	-0.3	0.21	-0.49	-0.15	-0.32	22.25	-0.1
Jan-67	1.7	-0.39	-0.29	-0.4	-0.2	23.66	-0.2
Feb-67	1.7	-0.02	-0.1	-0.33	-0.18	25.54	-0.3
Mar-67	1.2	-0.44	-0.29	-0.35	-1.2	25.55	-0.4
Apr-67	0	-0.27	-0.59	-0.59	-0.89	24.98	-0.5
May-67	0	-0.64	-0.21	-0.3	-1.24	23.77	-0.4
Jun-67	0.6	-0.89	0.1	0.14	-1.16	22.04	-0.2
Jul-67	0.2	-0.73	-0.24	0.17	-0.89	21.1	0.1
Aug-67	0.7	-0.98	-0.76	-0.28	-1.24	19.84	0.1
Sep-67	0.5	-1.19	-1	-0.56	-0.72	19.08	-0.1
Oct-67	0.1	-0.99	-0.92	-0.48	-0.64	19.47	-0.3
Nov-67	-0.4	-1.45	-0.92	-0.36	-0.05	20.2	-0.3
Dec-67	-0.6	-1.19	-0.87	-0.52	-0.4	21.28	-0.3
Jan-68	0.5	-1.12	-1.02	-0.73	-0.95	23.19	-0.4
Feb-68	1.3	-0.87	-1.24	-0.81	-0.4	24.88	-0.6
Mar-68	0.1	-1.06	-1.09	-0.68	-0.31	25.11	-0.8
Apr-68	0	-1.11	-0.62	-0.45	-1.03	23.97	-0.7
May-68	1.2	-1.43	-0.57	-0.24	-0.53	22.44	-0.5
Jun-68	1.1	-0.87	0.09	0.39	-0.35	21.7	-0.2
Jul-68	0.7	-0.26	0.6	0.66	0.53	21.25	0.1
Aug-68	0.3	0.06	0.43	0.43	0.19	20.97	0.4
Sep-68	-0.3	0.65	0.36	0.13	0.06	21.23	0.5
Oct-68	-0.1	0.35	0.3	0.28	-0.34	21.12	0.5
Nov-68	-0.3	0.08	0.56	0.74	-0.44	21.68	0.6
Dec-68	0.2	0.43	0.69	0.82	-1.27	23.2	0.8
Jan-69	-1.5	0.22	0.95	1.32	-1.26	24.67	1
Feb-69	-0.5	0	0.52	1.05	-0.95	25.56	1.1
Mar-69	0.4	0.88	0.53	0.54	-0.5	27.09	1.1
Apr-69	-0.4	1.37	0.52	0.34	-0.44	26.66	1
May-69	-0.2	1.84	1.13	0.76	-0.2	26.07	0.9
Jun-69	0.2	1.59	0.96	0.54	0.89	24.39	0.8
Jul-69	-0.5	0.65	0.44	0.36	0.1	22.47	0.6
Aug-69	-0.1	0.17	0.56	0.35	-0.81	21.06	0.5
Sep-69	-1	0.41	1.05	0.73	-0.66	20.88	0.5
Oct-69	-0.9	1.36	1.01	0.85	1.12	21.74	0.8
Nov-69	-0.1	0.88	1.07	0.84	0.15	22.47	0.9
Dec-69	0.4	0.87	1.12	0.93	1.38	23.6	0.9



Jan-70	-1.1	0.5	1.11	0.97	0.61	25.02	0.8
Feb-70	-1	-0.05	0.65	0.81	0.43	25.76	0.6
Mar-70	0.6	-0.68	0.31	0.58	1.33	25.53	0.4
Apr-70	-0.1	-0.73	0.25	0.61	0.43	24.76	0.4
May-70	0.4	-1.03	-0.22	0.37	-0.49	22.94	0.3
Jun-70	1	-1.53	-0.76	-0.24	0.06	21.27	0.1
Jul-70	-0.4	-2.06	-1.69	-0.87	-0.68	19.69	-0.2
Aug-70	0.6	-1.62	-1.71	-1.01	-1.63	19.27	-0.5
Sep-70	1.2	-1.11	-1.24	-1	-1.67	19.5	-0.7
Oct-70	1	-0.75	-1.11	-0.88	-1.39	20.16	-0.7
Nov-70	1.6	-0.53	-1.27	-1.17	-0.8	20.61	-0.7
Dec-70	1.9	-0.63	-1.65	-1.58	-0.97	21.77	-0.8
Jan-71	0.4	-1.06	-1.53	-1.53	-1.9	23.33	-1
Feb-71	2	-0.98	-1.32	-1.29	-1.74	24.58	-1.2
Mar-71	2.3	-0.97	-1.17	-1.28	-1.68	25.24	-1.3
Apr-71	1.7	-0.41	-0.46	-0.79	-1.59	24.95	-1.1
May-71	0.9	-0.77	-0.67	-0.61	-1.55	23.29	-0.8
Jun-71	0.4	-0.4	-0.57	-0.73	-1.55	21.6	-0.7
Jul-71	0.2	-0.42	-0.37	-0.42	-2.2	21.01	-0.7
Aug-71	1.5	-0.62	-0.6	-0.35	-0.15	19.97	-0.7
Sep-71	1.4	-0.79	-0.57	-0.7	0.21	19.74	-0.7
Oct-71	1.7	-0.3	-0.78	-0.85	-0.22	19.88	-0.7
Nov-71	0.5	-0.32	-0.85	-0.85	-1.25	20.94	-0.8
Dec-71	0.3	-0.11	-0.93	-0.98	-1.87	21.99	-0.9
Jan-72	0.5	-0.03	-0.33	-0.51	-1.99	24.51	-0.8
Feb-72	1.1	0.97	-0.2	-0.29	-1.83	26.66	-0.6
Mar-72	0.6	1.16	-0.03	-0.13	-2.09	27.09	-0.3
Apr-72	-0.1	1.57	0.42	0.24	-1.65	26.25	0.1
May-72	-1.6	1.94	0.83	0.42	-1.57	25.47	0.4
Jun-72	-0.5	2.15	1.06	0.79	-1.87	25.01	0.6
Jul-72	-1.4	2.7	1.46	0.92	-0.83	24.11	0.8
Aug-72	-0.5	2.78	1.94	1.35	0.25	23.42	1.1
Sep-72	-1.4	1.58	1.84	1.35	0.17	22.12	1.4
Oct-72	-0.9	1.86	2.04	1.89	0.11	22.58	1.6
Nov-72	-0.3	2	2.29	2.22	0.57	23.32	1.9
Dec-72	-1.3	2.27	2.32	2.07	-0.33	24.89	2.1
Jan-73	-0.3	1.91	1.64	1.53	-0.46	26.03	2.1
Feb-73	-1.4	0.74	1.27	1.38	-0.61	26.48	1.8

Mar-73	0.7	0.04	0.79	0.79	-0.5	26.27	1.2
Apr-73	0.1	-0.62	0.1	0.11	-0.69	24.87	0.6
May-73	0.4	-0.82	-0.89	-0.84	-0.76	23.44	-0.1
Jun-73	1.1	-0.8	-0.96	-1.1	-0.97	21.76	-0.5
Jul-73	0.6	-0.78	-1.04	-0.91	-0.57	20.84	-0.8
Aug-73	1.3	-1.28	-1.4	-1.5	-1.14	19.47	-1
Sep-73	1.2	-1.21	-1.24	-1.29	-0.51	19.49	-1.2
Oct-73	0.8	-1.44	-1.42	-1.71	-0.87	19.8	-1.3
Nov-73	2.6	-1.06	-1.56	-2.33	-1.81	20.71	-1.6
Dec-73	1.8	-0.98	-1.53	-2.21	-0.76	21.74	-1.9
Jan-74	2.4	-0.7	-1.39	-1.93	-1.22	23.29	-2
Feb-74	2.1	-0.49	-1.16	-1.74	-1.65	24.87	-1.9
Mar-74	2.4	-0.29	-0.44	-1.2	-0.9	25.69	-1.6
Apr-74	0.9	-0.01	-0.29	-1	-0.52	25.28	-1.2
May-74	1	0.2	0.13	-0.63	-0.28	24.35	-1
Jun-74	0.4	-0.11	0.26	-0.37	-0.31	22.48	-0.8
Jul-74	1.1	-0.13	-0.09	-0.88	-0.08	21.58	-0.7
Aug-74	0.8	-0.19	0.08	-0.35	0.27	20.73	-0.5
Sep-74	1.1	-0.46	-0.3	-0.32	0.44	20.15	-0.4
Oct-74	0.9	-0.95	-0.22	-0.61	-0.1	19.88	-0.4
Nov-74	-0.1	-0.59	-0.55	-0.93	0.43	20.68	-0.6
Dec-74	0.2	-0.67	-0.41	-0.69	-0.12	21.41	-0.8
Jan-75	-0.5	-0.82	-0.2	-0.17	-0.84	23.55	-0.7
Feb-75	0.8	-0.4	-0.4	-0.47	-0.71	24.95	-0.5
Mar-75	1.6	0.12	-0.4	-0.75	-0.51	26.06	-0.5
Apr-75	1.2	0.17	-0.04	-0.53	-1.3	25.53	-0.6
May-75	0.6	-0.55	-0.45	-0.73	-1.02	23.71	-0.7
Jun-75	1.3	-0.79	-0.86	-1.04	-1.16	21.84	-0.8
Jul-75	1.9	-0.53	-0.81	-1.11	-0.4	21.05	-1
Aug-75	2	-0.68	-0.5	-1.03	-1.07	19.97	-1.1
Sep-75	2.1	-1.22	-0.84	-0.94	-1.23	19.14	-1.2
Oct-75	1.7	-1.29	-1.1	-1.38	-1.29	19.17	-1.4
Nov-75	1.2	-1.43	-1.13	-1.47	-2.08	19.44	-1.5
Dec-75	2.1	-1.09	-1.47	-1.66	-1.61	21.05	-1.6
Jan-76	1.4	-0.41	-1.74	-1.82	-1.14	23.51	-1.7
Feb-76	1.7	-0.01	-1.04	-1.25	-1.85	25.36	-1.5
Mar-76	1.7	0.19	-0.25	-0.56	-0.96	25.88	-1.1
Apr-76	0.3	0.48	-0.05	-0.29	-0.89	25.72	-0.7



May-76	0.4	1.15	0.16	-0.3	-0.68	25.11	-0.5
Jun-76	0.3	1.82	0.75	0.04	-0.67	24.46	-0.3
Jul-76	-0.9	1.99	0.67	0.06	0.61	23.3	-0.1
Aug-76	-0.8	1.78	1.18	0.52	1.28	21.91	0.2
Sep-76	-1.1	1.46	1.21	0.87	0.82	21.56	0.4
Oct-76	0.4	1.23	1.32	0.89	1.11	21.69	0.6
Nov-76	0.7	0.98	1.12	0.82	1.25	22.14	0.7
Dec-76	-0.3	1.35	1.03	0.73	1.22	23.29	0.8
Jan-77	-0.4	1.15	1.21	0.93	1.65	24.93	0.8
Feb-77	1.2	0.31	0.7	0.42	1.11	25.79	0.6
Mar-77	-0.5	0.1	0.58	0.26	0.72	26.13	0.6
Apr-77	-0.4	-0.38	-0.24	-0.09	0.3	25.29	0.3
May-77	-0.5	-0.41	0.31	0.43	0.31	23.88	0.3
Jun-77	-0.9	0.05	0.33	0.65	0.42	22.7	0.3
Jul-77	-1.1	0.34	0.09	0.47	0.19	21.63	0.4
Aug-77	-0.8	-0.54	-0.37	0.21	0.64	20.25	0.4
Sep-77	-0.8	-0.41	-0.05	0.31	-0.55	19.82	0.4
Oct-77	-1	0.06	0.39	0.62	-0.61	20.61	0.5
Nov-77	-1.3	-0.3	0.62	1.04	-0.72	21.29	0.7
Dec-77	-1.1	-0.35	0.46	1.03	-0.69	22.47	0.8
Jan-78	-0.3	0.18	0.59	0.87	0.34	24.32	0.8
Feb-78	-2.7	0.16	0.29	0.45	1.45	25.77	0.7
Mar-78	-0.2	-0.38	0.05	0.26	1.34	25.39	0.5
Apr-78	-0.3	-0.25	-0.48	-0.31	1.29	24.73	0.1
May-78	1.4	-0.81	-0.28	-0.15	0.9	25.13	-0.2
Jun-78	0.7	-0.99	-0.65	-0.37	0.15	21.89	-0.3
Jul-78	0.6	-0.74	-0.67	-0.31	-1.24	21.01	-0.3
Aug-78	0.4	-1.16	-0.76	-0.48	-0.56	19.66	-0.3
Sep-78	0.1	-0.75	-0.5	-0.34	-0.44	19.98	-0.4
Oct-78	-0.4	-0.48	-0.33	-0.68	0.1	20.22	-0.4
Nov-78	0	0.3	-0.04	-0.09	-0.07	21.62	-0.3
Dec-78	-0.1	0.58	0.24	-0.04	-0.43	22.94	-0.1
Jan-79	-0.4	0.53	-0.11	0.12	-0.58	24.71	-0.1
Feb-79	1	-0.01	0.01	0.16	-1.33	25.6	-0.1
Mar-79	0.1	-0.01	0.24	0.26	0.3	25.93	0.1
Apr-79	-0.1	0.1	0.46	0.41	0.89	25.58	0.2
May-79	0.5	-0.01	0.55	0.27	1.09	24.52	0.3
Jun-79	0.6	0.2	0.49	0.24	0.17	23.28	0.2

Jul-79	1.3	-0.02	0.1	-0.19	0.84	21.79	0
Aug-79	-0.2	0.51	0.52	0.05	0.52	21.05	0
Sep-79	0.1	0.65	1.07	0.63	1	21.15	0.2
Oct-79	-0.1	0.69	0.55	0.17	1.06	21.43	0.3
Nov-79	-0.4	0.19	0.34	0.2	0.48	21.95	0.5
Dec-79	-0.7	-0.07	0.55	0.66	-0.42	22.97	0.5
Jan-80	0.4	-0.09	0.46	0.53	-0.11	24.35	0.6
Feb-80	0.3	0.1	0.26	0.34	1.32	25.73	0.5
Mar-80	-0.4	0.33	0.14	0.23	1.09	26.46	0.4
Apr-80	-0.6	0.17	0.29	0.4	1.49	25.71	0.3
May-80	0	0.36	0.39	0.22	1.2	24.46	0.3
Jun-80	0	0.01	0.57	0.54	-0.22	22.88	0.4
Jul-80	0	-0.85	0.01	0.1	0.23	21.26	0.4
Aug-80	0.4	-0.24	-0.08	0.06	0.51	20.57	0.3
Sep-80	-0.5	-0.21	-0.15	0.05	0.1	20.45	0.1
Oct-80	0	-0.28	-0.34	-0.14	1.35	20.43	-0.1
Nov-80	-0.3	-0.32	0.18	0.12	0.37	21.23	0
Dec-80	-0.1	-0.46	0.5	0.43	-0.1	22.34	0
Jan-81	0.4	-1.18	-0.52	-0.41	0.59	22.98	-0.1
Feb-81	-0.2	-0.71	-0.6	-0.5	1.46	24.9	-0.4
Mar-81	-1.3	-0.31	-0.23	-0.14	0.99	25.94	-0.6
Apr-81	-0.1	-0.36	-0.51	-0.48	1.45	24.89	-0.5
May-81	0.8	-0.58	-0.03	-0.19	1.75	23.9	-0.4
Jun-81	1.2	-0.22	0.01	-0.19	1.69	22.57	-0.3
Jul-81	0.8	-0.41	-0.38	-0.62	0.84	21.1	-0.3
Aug-81	0.7	-0.19	-0.61	-0.54	0.18	20.03	-0.4
Sep-81	0.3	-0.19	-0.08	-0.13	0.42	20.09	-0.4
Oct-81	-0.4	-0.01	0.06	-0.14	0.18	20.58	-0.3
Nov-81	0.2	0.12	-0.52	-0.7	0.8	21.26	-0.2
Dec-81	0.5	0.57	0.25	-0.2	0.67	22.6	-0.2
Jan-82	1.2	-0.17	0.24	0.15	0.34	24.36	-0.1
Feb-82	0.3	-0.58	0.01	-0.02	0.2	25.42	-0.1
Mar-82	0.6	-1.31	-0.16	-0.02	0.19	25.4	0
Apr-82	0.1	-0.97	0.18	0.24	-0.19	24.96	0.1
May-82	-0.3	-0.23	0.71	0.69	-0.58	24.21	0.3
Jun-82	-1	0.07	1.03	1.1	-0.78	23.35	0.5
Jul-82	-1.5	0.87	0.82	0.88	0.58	22.5	0.7
Aug-82	-1.7	1.1	1.16	1.11	0.39	21.89	0.7

Sep-82	-1.7	1.44	1.67	1.39	0.84	22.04	1
Oct-82	-1.7	2.12	2.19	1.95	0.37	22.88	1.5
Nov-82	-2.6	3	2.64	2.16	-0.25	24.57	1.9
Dec-82	-2.2	3.34	3.25	2.64	0.26	25.89	2.1
Jan-83	-3.5	2.96	3.29	2.79	0.56	27.25	2.2
Feb-83	-3.6	2.02	2.55	2.41	1.14	28.23	2.2
Mar-83	-2.4	2.16	1.96	1.81	2.11	28.85	1.9
Apr-83	-0.9	3.09	1.62	1.13	1.87	28.82	1.5
May-83	0.6	3.99	1.89	1.04	1.8	28.37	1.2
Jun-83	0	4.62	1.72	0.59	2.36	27.43	0.9
Jul-83	-0.6	4.35	1	-0.15	3.51	25.73	0.6
Aug-83	0.1	3.13	0.88	-0.29	1.85	23.88	0.2
Sep-83	0.9	1.88	0.39	-0.28	0.91	22.26	-0.2
Oct-83	0.4	1.04	-0.31	-0.82	0.96	22.22	-0.5
Nov-83	-0.1	0.31	-0.81	-1.07	1.02	22.21	-0.8
Dec-83	0	0.22	-0.7	-0.98	1.69	23.19	-0.9
Jan-84	0.2	-0.28	-0.81	-0.93	1.5	24.32	-0.8
Feb-84	0.9	-0.89	-0.15	-0.33	1.21	25.12	-0.5
Mar-84	-0.2	-0.52	-0.02	-0.36	1.77	25.75	-0.3
Apr-84	0.3	-0.31	-0.16	-0.39	1.52	25.4	-0.3
May-84	0.2	-0.97	-0.62	-0.46	1.3	23.58	-0.4
Jun-84	-0.3	-0.86	-1.05	-0.79	0.18	22.3	-0.5
Jul-84	0.2	-0.36	-0.66	-0.48	-0.18	21.53	-0.5
Aug-84	0.4	-0.48	-0.49	-0.48	-0.03	20.64	-0.3
Sep-84	0.1	0.01	-0.5	-0.29	0.67	20.73	-0.2
Oct-84	-0.3	-0.3	-0.97	-0.76	0.58	20.62	-0.3
Nov-84	0.3	-0.09	-0.95	-1.24	0.71	21.7	-0.6
Dec-84	-0.1	-0.21	-1.44	-1.57	0.82	22.47	-0.9
Jan-85	-0.3	-0.87	-1.12	-1.14	1.27	23.84	-1.1
Feb-85	1.2	-1.2	-1.18	-1.05	0.94	24.83	-1
Mar-85	0.8	-0.78	-1.03	-0.99	0.57	25.6	-0.9
Apr-85	1.2	-1.22	-0.98	-0.98	0.19	24.28	-0.7
May-85	0.4	-1.91	-0.96	-0.74	0	22.67	-0.7
Jun-85	-0.4	-1.07	-0.83	-0.79	0.18	21.84	-0.7
Jul-85	-0.1	-1.16	-0.88	-0.53	1.07	20.75	-0.6
Aug-85	1	-1.36	-0.59	-0.32	0.81	19.9	-0.5
Sep-85	0	-0.92	-0.7	-0.47	0.44	19.86	-0.5
Oct-85	-0.4	-0.92	-0.77	-0.5	0.29	20.26	-0.5

Nov-85	-0.2	-0.9	-0.7	-0.46	-0.75	20.97	-0.4
Dec-85	0.2	-0.39	-0.85	-0.46	0.38	22.49	-0.4
Jan-86	1	0.15	-0.9	-0.78	1.12	24.31	-0.4
Feb-86	-1	-0.01	-0.56	-0.78	1.61	25.9	-0.5
Mar-86	0.5	-0.61	-0.3	-0.57	2.18	25.78	-0.4
Apr-86	0.3	-0.89	-0.33	-0.34	1.55	24.86	-0.2
May-86	-0.2	-0.82	-0.4	-0.35	1.16	23.35	-0.2
Jun-86	1	-0.84	-0.13	0.04	0.89	22.03	-0.1
Jul-86	0.3	-0.48	0.08	0.15	1.38	21.64	0
Aug-86	-0.4	0.32	0.03	0.33	0.22	21.07	0.3
Sep-86	-0.5	0.08	0.4	0.61	0.22	21.13	0.5
Oct-86	0.6	0.25	0.7	0.88	1	21.46	0.7
Nov-86	-1.2	0.44	0.94	1.08	1.77	22.17	0.9
Dec-86	-1.4	0.21	0.72	1.13	1.77	23.53	1.1
Jan-87	-0.7	0.84	1.06	1.34	1.88	25.6	1.2
Feb-87	-1.2	1.07	1.05	1.3	1.75	27.02	1.2
Mar-87	-1.3	1.49	1.06	1.25	2.1	27.89	1.3
Apr-87	-1.4	1.7	0.99	1.02	2.16	26.95	1.2
May-87	-1.3	1.38	1.14	0.9	1.85	25.96	1.1
Jun-87	-1.1	1.24	1.28	1.38	0.73	24.04	1
Jul-87	-1.4	1.18	1.45	1.58	2.01	23	1.2
Aug-87	-0.9	1.08	1.53	1.76	2.83	21.92	1.4
Sep-87	-1	1.09	1.72	1.67	2.44	22	1.6
Oct-87	-0.4	1.57	1.28	1.38	1.36	22.54	1.6
Nov-87	0	1.04	1.15	1.34	1.47	22.84	1.5
Dec-87	-0.5	0.68	1.06	1.03	1.27	23.51	1.3
Jan-88	-0.1	0.18	0.49	0.75	0.93	24.76	1.1
Feb-88	-0.4	-0.33	0.18	0.5	1.24	25.74	0.8
Mar-88	0.6	-0.74	0	0.09	1.42	25.71	0.5
Apr-88	0.1	-0.93	-0.77	-0.46	0.94	24.68	0.1
May-88	0.9	-0.6	-1.86	-1.37	1.2	23.18	-0.2
Jun-88	0.1	-1.55	-1.97	-1.54	0.74	21.66	-0.8
Jul-88	1	-1.34	-1.91	-1.65	0.64	20.59	-1.2
Aug-88	1.5	-1.53	-1.62	-1.58	0.19	19.63	-1.3
Sep-88	1.8	-1.17	-1.24	-1.29	-0.37	19.44	-1.2
Oct-88	1.4	-1.32	-1.75	-2.07	-0.1	19.83	-1.3
Nov-88	1.7	-1.04	-1.95	-2.38	-0.02	20.96	-1.6
Dec-88	1.2	-0.99	-2.07	-2.24	-0.43	22.25	-1.9



Jan-89	1.5	-0.37	-1.48	-2.04	-0.95	24.36	-1.9
Feb-89	1.2	0.19	-0.76	-1.39	-1.02	26.02	-1.7
Mar-89	1.1	0.14	-1.12	-1.32	-0.83	26.21	-1.5
Apr-89	1.6	0.16	-0.83	-1.09	-0.32	25.54	-1.1
May-89	1.2	-1.02	-0.71	-0.76	0.47	23.36	-0.8
Jun-89	0.7	-0.82	-0.35	-0.67	0.36	22.14	-0.6
Jul-89	0.9	-0.48	-0.34	-0.48	0.83	21.27	-0.4
Aug-89	-0.3	-0.33	-0.43	-0.49	0.09	20.86	-0.3
Sep-89	0.5	-0.49	-0.4	-0.47	0.05	20.17	-0.3
Oct-89	0.8	-0.49	-0.43	-0.43	-0.12	20.52	-0.3
Nov-89	-0.2	-0.28	-0.42	-0.41	-0.5	21.44	-0.3
Dec-89	-0.5	-0.6	-0.43	-0.19	-0.21	22.61	-0.2
Jan-90	-0.1	-0.44	-0.29	-0.02	-0.3	24.22	-0.1
Feb-90	-1.8	-0.19	0	0.23	-0.65	26.17	0.1
Mar-90	-0.4	-0.36	-0.11	0.24	-0.62	26.15	0.2
Apr-90	0.2	-0.25	0.17	0.24	0.27	25.15	0.3
May-90	1.2	-0.15	0.27	0.21	0.44	24.14	0.3
Jun-90	0.3	-0.14	0.02	-0.07	0.44	22.76	0.2
Jul-90	0.5	-0.6	-0.17	0.03	0.27	21.36	0.2
Aug-90	-0.2	-0.4	0.07	0.23	0.11	20.7	0.3
Sep-90	-0.7	-0.23	0	0.03	0.38	20.28	0.3
Oct-90	0.3	-0.54	-0.02	0.29	-0.69	20.4	0.4
Nov-90	-0.5	-0.75	-0.16	0.07	-1.69	21.19	0.3
Dec-90	-0.2	-0.34	-0.06	0.34	-2.23	22.29	0.4
Jan-91	0.6	-0.6	0.02	0.44	-2.02	23.99	0.4
Feb-91	0.3	-0.1	-0.1	0.21	-1.19	25.59	0.3
Mar-91	-0.7	-0.01	-0.15	0.03	-0.74	26.31	0.2
Apr-91	-0.6	-0.48	-0.18	0.2	-1.01	25.15	0.2
May-91	-1	0.17	0.5	0.5	-0.51	24.44	0.3
Jun-91	-0.1	0.23	0.91	0.71	-1.47	23.28	0.5
Jul-91	0	0.45	0.95	0.7	-0.1	22.39	0.7
Aug-91	-0.4	0.43	0.48	0.62	0.36	21.39	0.8
Sep-91	-1.5	0.39	0.2	0.35	0.65	21.22	0.7
Oct-91	-1	0.31	0.68	0.94	0.49	21.73	0.7
Nov-91	-0.7	0.59	1	1.21	0.42	22.4	0.8
Dec-91	-1.8	0.64	1.38	1.8	0.09	23.75	1.2
Jan-92	-2.9	0.37	1.37	1.84	0.05	25.02	1.4
Feb-92	-0.9	0.61	1.3	1.91	0.31	26.62	1.6

Mar-92	-2	1.24	1.19	1.61	0.67	27.72	1.5
Apr-92	-1	2.21	1.22	1.36	0.75	27.58	1.4
May-92	0.3	2.11	1.35	1.14	1.54	26.44	1.2
Jun-92	-0.6	1	0.23	0.37	1.26	23.86	1
Jul-92	-0.6	0.35	-0.09	0.31	1.9	21.84	0.7
Aug-92	0.4	-0.1	-0.29	-0.18	1.44	20.87	0.3
Sep-92	0.1	-0.3	-0.33	-0.24	0.83	20.85	0
Oct-92	-1.4	0	-0.3	-0.35	0.93	21.15	-0.2
Nov-92	-0.7	-0.1	-0.19	-0.14	0.93	21.84	-0.3
Dec-92	-0.6	-0.31	-0.13	0.16	0.53	22.79	-0.2
Jan-93	-0.9	-0.03	-0.07	0.12	0.05	24.68	0
Feb-93	-0.7	0.42	0.24	0.25	0.19	26.46	0.2
Mar-93	-0.5	0.65	0.4	0.44	0.76	27.07	0.3
Apr-93	-1.2	0.97	0.95	0.81	1.21	26.84	0.5
May-93	-0.3	0.95	1.08	0.97	2.13	25.6	0.6
Jun-93	-0.8	0.94	0.68	0.63	2.34	24.11	0.6
Jul-93	-0.8	0.46	0.15	0.33	2.35	22.61	0.5
Aug-93	-0.9	0.4	-0.06	0.02	2.69	21.65	0.3
Sep-93	-0.7	0.47	0.12	0.2	1.56	21.11	0.2
Oct-93	-1.1	0.17	0.29	0.24	1.41	21.71	0.2
Nov-93	-0.1	0.05	0.19	0.26	1.24	22.07	0.2
Dec-93	0.2	-0.04	0.18	0.19	1.07	22.86	0.1
Jan-94	-0.1	-0.14	0.08	0.03	1.21	24.56	0.1
Feb-94	0.3	-0.28	-0.3	-0.13	0.59	25.89	0.1
Mar-94	-0.7	-1.09	-0.25	0.05	0.8	25.75	0.1
Apr-94	-1.3	-1.15	-0.44	0.12	1.05	24.49	0.2
May-94	-0.7	-0.98	-0.11	0.19	1.23	23.52	0.3
Jun-94	-0.4	-0.39	0.07	0.34	0.46	22.31	0.4
Jul-94	-1.3	-0.39	-0.43	0.13	0.06	21.17	0.4
Aug-94	-1.2	-0.95	-0.28	0.53	-0.79	20.22	0.4
Sep-94	-1.6	-0.2	-0.04	0.28	-1.36	20.65	0.4
Oct-94	-1.1	0.71	0.61	0.8	-1.32	22.04	0.5
Nov-94	-0.6	0.82	0.89	1.22	-1.96	22.27	0.7
Dec-94	-1.2	0.82	0.93	1.3	-1.79	23.75	1
Jan-95	-0.4	0.87	0.71	0.98	-0.49	25.48	1.2
Feb-95	-0.1	0.36	0.5	0.73	0.46	26.25	1
Mar-95	0.8	-0.4	-0.06	0.41	0.75	26.09	0.8
Apr-95	-0.7	-1	-0.4	0.15	0.83	24.32	0.6

May-95	-0.4	-1.1	-0.68	-0.12	1.46	23.37	0.3
Jun-95	0.1	-0.37	-0.23	-0.06	1.27	22.43	0.2
Jul-95	0.4	-0.37	-0.2	-0.21	1.71	21.42	0
Aug-95	0.3	-0.64	-0.66	-0.49	0.21	20.46	-0.2
Sep-95	0.3	-0.19	-0.83	-0.76	1.16	20.5	-0.4
Oct-95	0	-0.67	-0.91	-1.02	0.47	20.62	-0.7
Nov-95	0	-0.39	-0.95	-0.99	-0.28	21.49	-0.8
Dec-95	-0.5	-0.77	-0.95	-1	0.16	22.03	-0.9
Jan-96	1	-0.62	-0.67	-0.83	0.59	23.81	-0.9
Feb-96	0.3	-0.36	-0.65	-0.87	0.75	25.52	-0.9
Mar-96	1.1	-0.43	-0.43	-0.6	1.01	26.28	-0.8
Apr-96	0.8	-1.62	-0.78	-0.42	1.46	24	-0.6
May-96	0.3	-1.31	-0.75	-0.48	2.18	23.11	-0.4
Jun-96	1.2	-1.26	-0.54	-0.33	1.1	21.66	-0.3
Jul-96	0.7	-1.58	-0.27	-0.13	0.77	20.72	-0.2
Aug-96	0.7	-1.12	-0.39	-0.26	-0.14	20.23	-0.2
Sep-96	0.6	-1.12	-0.48	-0.37	0.24	20.43	-0.3
Oct-96	0.6	-0.87	-0.55	-0.45	-0.33	20.52	-0.3
Nov-96	-0.1	-1.33	-0.6	-0.46	0.09	20.77	-0.3
Dec-96	0.9	-1.18	-0.94	-0.55	-0.03	21.68	-0.4
Jan-97	0.5	-0.79	-0.93	-0.61	0.23	23.7	-0.5
Feb-97	1.7	-0.33	-0.62	-0.36	0.28	26.08	-0.5
Mar-97	-0.4	0.43	-0.16	-0.19	0.65	27.17	-0.4
Apr-97	-0.6	1.17	0.09	0.25	1.05	26.74	-0.1
May-97	-1.3	2.51	0.98	0.75	1.83	26.77	0.2
Jun-97	-1.4	3.45	1.71	1.29	2.76	26.15	0.7
Jul-97	-0.8	3.99	2.39	1.7	2.35	25.59	1.2
Aug-97	-1.4	4.15	2.85	2.02	2.79	24.95	1.5
Sep-97	-1.4	4.04	2.99	2.21	2.19	24.69	1.8
Oct-97	-1.5	3.76	3.25	2.54	1.61	24.64	2.1
Nov-97	-1.2	4.04	3.57	2.67	1.12	25.85	2.3
Dec-97	-1	4.13	3.62	2.69	0.67	27.08	2.4
Jan-98	-2.7	3.76	3.31	2.53	0.83	28.12	2.3
Feb-98	-2	2.91	2.56	2.14	1.56	28.82	2.2
Mar-98	-2.4	2.63	2	1.45	2.01	29.24	1.8
Apr-98	-1.4	3.14	1.59	0.78	1.27	28.45	1.4
May-98	0.3	3.49	1.09	0.62	0.7	27.36	0.9
Jun-98	1	2.36	-0.43	-0.93	0.4	25.19	0.4



Jul-98	1.2	1.83	-0.38	-1.28	-0.04	23.61	-0.2
Aug-98	1.2	1.12	-0.36	-1.33	-0.22	22.27	-0.7
Sep-98	1	0.51	-0.66	-1.11	-1.21	21.31	-1
Oct-98	1.1	0.34	-0.86	-1.35	-1.39	21.37	-1.2
Nov-98	1	-0.16	-0.87	-1.47	-0.52	21.6	-1.3
Dec-98	1.4	-0.23	-1.28	-1.78	-0.44	22.81	-1.4
Jan-99	1.8	-0.73	-1.22	-1.67	-0.32	24.23	-1.5
Feb-99	1	-0.43	-0.8	-1.31	-0.66	25.73	-1.5
Mar-99	1.3	0.1	-0.47	-0.97	-0.33	26.47	-1.3
Apr-99	1.4	-1.17	-0.84	-0.94	-0.41	24.53	-1
May-99	0.2	-0.74	-0.64	-0.88	-0.68	23.64	-0.9
Jun-99	0.3	-0.99	-0.84	-1.05	-1.3	22.09	-0.9
Jul-99	0.5	-1.16	-0.77	-0.87	-0.66	21.36	-1
Aug-99	0.4	-0.9	-0.97	-1.23	-0.96	20.67	-1
Sep-99	-0.1	-1.13	-1.13	-1.01	-1.53	20.08	-1.1
Oct-99	1	-0.77	-1.17	-1.05	-2.23	20.46	-1.1
Nov-99	1	-1.08	-1.52	-1.53	-2.05	20.62	-1.3
Dec-99	1.4	-1.07	-1.6	-1.67	-1.63	22.42	-1.5
Jan-00	0.7	-0.6	-1.75	-1.92	-2	24.01	-1.7
Feb-00	1.7	-0.36	-1.06	-1.53	-0.83	25.38	-1.7
Mar-00	1.3	-0.33	-0.53	-1.14	0.29	25.67	-1.5
Apr-00	1.2	0.37	-0.04	-0.77	0.35	25.53	-1.2
May-00	0.4	-0.1	-0.28	-0.73	-0.05	24.27	-0.9
Jun-00	-0.2	-0.57	-0.59	-0.62	-0.44	22.93	-0.8
Jul-00	-0.2	-1.01	-0.49	-0.5	-0.66	21.47	-0.7
Aug-00	0.7	-0.55	-0.52	-0.37	-1.19	20.07	-0.6
Sep-00	0.9	-0.42	-0.5	-0.51	-1.24	20.64	-0.5
Oct-00	1.1	-0.45	-0.51	-0.73	-1.3	20.9	-0.6
Nov-00	1.8	-0.99	-0.81	-0.87	-0.53	20.67	-0.6
Dec-00	0.8	-0.57	-0.71	-0.98	0.52	22.07	-0.8
Jan-01	1	-0.58	-0.64	-0.83	0.6	24.25	-0.8
Feb-01	1.7	-0.16	-0.31	-0.61	0.29	26.11	-0.7
Mar-01	0.9	0.92	0.09	-0.38	0.45	26.9	-0.6
Apr-01	0.2	1.22	0.02	-0.26	-0.31	25.99	-0.5
May-01	-0.5	-0.43	-0.19	-0.25	-0.3	23.97	-0.4
Jun-01	0.3	-1.08	-0.08	0.03	-0.47	22.71	-0.2
Jul-01	-0.2	-0.72	-0.19	0.1	-1.31	21.48	-0.1
Aug-01	-0.4	-0.75	-0.27	0.05	-0.77	20.23	0

Sep-01	0.2	-0.97	-0.58	-0.17	-1.37	19.73	0
Oct-01	0	-1.3	-0.47	-0.1	-1.37	20.14	-0.1
Nov-01	0.7	-1.1	-0.63	-0.2	-1.26	20.68	-0.2
Dec-01	-0.8	-0.83	-0.54	-0.4	-0.93	21.72	-0.3
Jan-02	0.4	-0.82	-0.54	-0.07	0.27	24.09	-0.3
Feb-02	1.1	-0.01	-0.16	0.23	-0.64	26.22	-0.2
Mar-02	-0.2	1.01	0.08	0.1	-0.43	27.38	0
Apr-02	-0.1	1.06	0.06	0.16	-0.32	26.44	0.1
May-02	-0.8	0.6	0.16	0.3	-0.63	25.28	0.3
Jun-02	-0.2	-0.15	0.63	0.78	-0.35	23.27	0.5
Jul-02	-0.5	-0.59	0.41	0.76	-0.31	21.62	0.7
Aug-02	-1	-0.71	0.48	0.97	0.6	21.3	0.8
Sep-02	-0.6	-0.47	0.69	1.11	0.43	21.41	0.8
Oct-02	-0.4	0.34	0.93	1.36	0.42	21.84	0.9
Nov-02	-0.5	0.66	1.39	1.62	1.51	22.84	1.2
Dec-02	-1.1	0.65	1.34	1.52	2.1	24.05	1.3
Jan-03	-0.2	-0.08	0.75	1.19	2.09	24.99	1.3
Feb-03	-0.7	-0.26	0.33	0.77	1.75	26.26	1.1
Mar-03	-0.3	-0.55	0.14	0.59	1.51	26.91	0.8
Apr-03	-0.1	-1.03	-0.35	0.03	1.18	25.41	0.4
May-03	-0.3	-1.71	-0.94	-0.48	0.89	23.24	0
Jun-03	-0.6	-1.24	-0.6	-0.17	0.68	22.14	-0.2
Jul-03	0.3	-0.85	0.13	0.21	0.96	21.5	-0.1
Aug-03	0.1	-0.51	0.05	0.03	0.88	21.25	0.2
Sep-03	-0.1	-0.36	0.12	0.24	0.01	20.75	0.4
Oct-03	0	0.17	0.41	0.5	0.83	21.7	0.4
Nov-03	-0.3	0.33	0.42	0.4	0.52	22.33	0.4
Dec-03	1.1	0.2	0.42	0.32	0.33	23.61	0.4
Jan-04	-1.3	0.14	0.29	0.17	0.43	25.08	0.3
Feb-04	1.2	-0.26	0.09	0.14	0.48	26.48	0.3
Mar-04	0.4	-0.58	0.02	-0.12	0.61	26.13	0.2
Apr-04	-0.9	-0.15	-0.13	0.06	0.57	25.29	0.1
May-04	1	-1.15	-0.36	0.21	0.88	23.47	0.1
Jun-04	-0.8	-1.22	-0.16	0.11	0.04	22.55	0.2
Jul-04	-0.5	-0.89	-0.21	0.47	0.44	21.26	0.3
Aug-04	-0.3	-1.03	0.06	0.72	0.85	20.8	0.5
Sep-04	-0.3	-0.29	0.32	0.75	0.75	20.85	0.7
Oct-04	-0.1	0.1	0.4	0.69	-0.11	21.58	0.8



Nov-04	-0.7	0.37	0.48	0.66	-0.63	22.89	0.7
Dec-04	-0.8	0.15	0.63	0.74	-0.17	23.39	0.7
Jan-05	0.3	0.01	0.26	0.53	0.44	24.62	0.7
Feb-05	-3.1	-0.58	-0.17	0.24	0.81	25.09	0.6
Mar-05	0.3	0.92	-0.13	0.33	1.36	25.23	0.4
Apr-05	-0.6	-0.57	0.27	0.29	1.03	25.19	0.3
May-05	-0.8	0.2	0.4	0.35	1.86	24.31	0.3
Jun-05	0.4	-0.35	0.38	0.4	1.17	22.59	0.3
Jul-05	0.2	-0.42	0.31	0.25	0.66	21.57	0.3
Aug-05	-0.3	-0.04	0.2	0.06	0.25	20.46	0.2
Sep-05	0.4	-0.65	-0.28	-0.09	-0.46	19.98	0.1
Oct-05	1.2	-1.1	-0.23	0.06	-1.32	19.87	0
Nov-05	-0.2	-0.97	-0.7	-0.31	-1.5	20.59	-0.2
Dec-05	0	-0.5	-0.86	-0.68	0.2	22.2	-0.5
Jan-06	1.7	-0.13	-0.63	-0.93	1.03	24.74	-0.8
Feb-06	0.1	0.39	-0.29	-0.64	0.66	26.49	-0.9
Mar-06	1.8	0.25	-0.6	-0.65	0.05	26.2	-0.7
Apr-06	1.1	-1.32	-0.25	-0.19	0.4	24.26	-0.5
May-06	-0.5	-0.34	-0.04	0.06	0.48	23.82	-0.3
Jun-06	-0.2	-0.05	0.01	0.2	1.04	22.8	0
Jul-06	-0.6	0.59	0.18	0.13	0.35	22.18	0.1
Aug-06	-1	0.94	0.46	0.4	-0.65	21.87	0.2
Sep-06	-0.6	1.07	0.89	0.62	-0.94	21.92	0.3
Oct-06	-1.3	1.4	1.04	0.78	-0.05	22.44	0.5
Nov-06	0.1	1.1	1.09	1.08	-0.22	22.62	0.8
Dec-06	-0.3	0.66	1.22	1.19	0.14	24.26	1
Jan-07	-0.8	0.53	0.87	0.69	0.01	25.92	1
Feb-07	-0.1	0.17	0.08	0.09	0.04	26.92	0.7
Mar-07	0.2	-0.78	-0.35	-0.04	-0.36	26.37	0.3
Apr-07	-0.1	-1.17	-0.37	0	0.16	24.78	-0.1
May-07	-0.1	-1.47	-0.73	-0.28	-0.1	23.03	-0.2
Jun-07	0.5	-1.23	-0.6	-0.1	0.09	21.62	-0.3
Jul-07	-0.3	-1.33	-0.83	-0.43	0.78	20.99	-0.3
Aug-07	0.4	-1.49	-1.13	-0.62	0.5	19.57	-0.4
Sep-07	0.2	-1.79	-1.33	-0.95	-0.36	19.77	-0.6
Oct-07	0.7	-2.02	-1.56	-1.47	-1.45	19.27	-0.8
Nov-07	0.9	-2.1	-1.81	-1.59	-1.08	19.82	-1.1
Dec-07	1.7	-1.77	-1.55	-1.6	-0.58	21.14	-1.2

Jan-08	1.8	-0.6	-1.5	-1.86	-1	24.25	-1.4
Feb-08	2.6	0.25	-1.32	-1.89	-0.77	26.39	-1.5
Mar-08	1.4	0.78	-0.58	-1.15	-0.71	26.91	-1.5
Apr-08	0.7	0.42	-0.32	-0.95	-1.52	25.68	-1.2
May-08	-0.1	0.21	0	-0.67	-1.37	24.41	-0.9
Jun-08	0.6	0.73	0.1	-0.48	-1.34	23.18	-0.7
Jul-08	0.3	1.03	0.5	-0.03	-1.67	23.03	-0.5
Aug-08	1	1.14	0.64	0.03	-1.7	22.14	-0.3
Sep-08	1.2	0.83	0.24	-0.28	-1.55	21.6	-0.2
Oct-08	1.3	-0.07	-0.13	-0.36	-1.76	21.39	-0.1
Nov-08	1.3	-0.15	-0.23	-0.35	-1.25	21.65	-0.2
Dec-08	1.4	-0.36	-0.54	-0.83	-0.87	22.65	-0.5
Jan-09	1.1	-0.1	-0.6	-1.03	-1.4	24.28	-0.7
Feb-09	1.9	-0.11	-0.52	-0.68	-1.55	25.46	-0.8
Mar-09	0.4	-0.26	-0.7	-0.55	-1.59	25.61	-0.7
Apr-09	0.8	0.37	-0.11	-0.27	-1.65	25.96	-0.5
May-09	-0.1	0.56	0.32	0.18	-0.88	24.97	-0.2
Jun-09	0.1	0.85	0.69	0.47	-0.31	24.07	0.2
Jul-09	0.2	1.02	0.94	0.72	-0.53	23.16	0.4
Aug-09	-0.2	1	0.95	0.71	0.09	21.96	0.5
Sep-09	0.3	0.47	0.8	0.75	0.52	21.46	0.6
Oct-09	-1.2	0.17	0.81	0.94	0.27	21.47	0.8
Nov-09	-0.6	0.51	1.26	1.54	-0.4	22.12	1.1
Dec-09	-0.7	0.35	1.53	1.72	0.08	23.22	1.4

Anexo 2: Datos de Lluvia y caudales de la microcuenca El Labrado

Tiempo	Lluvia (mm)	Caudal m3/s	Tiempo	Lluvia (mm)	Caudal m3/s
Jan-64	28.4	0.259	Jan-87	66.1	0.385
Feb-64	73.9	0.339	Feb-87	114.8	0.897
Mar-64	60.9	0.335	Mar-87	97.1	1.126
Apr-65	165.6	2.033	Apr-87	147.6	1.706
May-64	94	1.122	May-87	119.2	1.934
Jun-64	144.1	2.069	Jun-87	48.6	0.666
Jul-64	44.4	0.9	Jul-87	86.4	0.692
Aug-64	95.6	1.253	Aug-87	68.5	0.447
Sep-64	147.5	1.923	Sep-87	86.8	0.859
Oct-64	40.1	0.515	Oct-87	94.3	0.759
Nov-64	84.3	0.484	Nov-87	107.6	0.721
Dec-64	79.4	0.66	Dec-87	34.6	0.262
Jan-65	64.3	0.519	Jan-88	149.8	1.583
Feb-65	54.3	0.494	Feb-88	140.9	1.891
Mar-65	85.3	0.581	Mar-88	52.8	0.755
Apr-65	206.5	2.43	Apr-88	264.4	3.176
May-65	139.1	2.053	May-88	102.2	1.982
Jun-65	102.6	1.712	Jun-88	53.2	0.953
Jul-65	73.3	1	Jul-88	81.8	0.991
Aug-65	72.9	0.749	Aug-88	84.1	1.049
Sep-65	113.6	0.914	Sep-88	45.1	0.563
Oct-65	111.4	0.732	Oct-88	121.4	1.536
Nov-65	131.1	1.741	Nov-88	163.9	2.128
Dec-65	77.2	0.751	Dec-88	121.3	1.545
Jan-66	111.8	0.927	Jan-89	171.2	2.263
Feb-66	85.3	1.1	Feb-89	175.2	2.179
Mar-66	110.4	1.173	Mar-89	159.7	2.697
Apr-66	92.6	0.989	Apr-89	80	1.372
May-66	81.5	0.734	May-89	81.6	0.737
Jun-66	66.7	0.686	Jun-89	125.1	1.569
Jul-66	82.7	0.872	Jul-89	95	1.436
Aug-66	67.8	0.659	Aug-89	31.8	0.413
Sep-66	73.4	0.573	Sep-89	93.8	0.696
Oct-66	59.1	0.404	Oct-89	103.2	1.658
Nov-66	67.9	0.407	Nov-89	27.2	0.312
Dec-66	68.4	0.317	Dec-89	22.7	0.076

Jan-67	127.1	0.798	Jan-90	101.5	0.711
Feb-67	121.3	1.416	Feb-90	62.7	0.925
Mar-67	83.3	0.847	Mar-90	118.8	0.678
Apr-67	95.8	0.846	Apr-90	140.5	2.347
May-67	90.8	1.056	May-90	128.4	1.214
Jun-67	129.3	1.948	Jun-90	89.3	1.167
Jul-67	153.3	2.194	Jul-90	81.8	1.023
Aug-67	123.7	1.561	Aug-90	82.1	0.657
Sep-67	55.5	0.648	Sep-90	90	0.327
Oct-67	141.1	1.483	Oct-90	153.9	2.188
Nov-67	55.8	0.47	Nov-90	91.2	1.156
Dec-67	21.2	0.142	Dec-90	55.7	0.513
Jan-68	111.5	0.597	Jan-91	42.8	0.322
Feb-68	112.1	0.924	Feb-91	63.1	0.939
Mar-68	194.4	2.423	Mar-91	126.1	1.326
Apr-68	66.2	0.904	Apr-91	102	0.649
May-68	73.6	0.641	May-91	131	0.933
Jun-68	118.6	1.301	Jun-91	100	1.021
Jul-68	125.8	1.767	Jul-91	118.9	1.019
Aug-68	74.3	0.866	Aug-91	87.1	0.825
Sep-68	69.1	0.806	Sep-91	61.7	0.683
Oct-68	147.2	1.22	Oct-91	100.4	0.645
Nov-68	52.9	0.341	Nov-91	158.6	1.743
Dec-68	23.5	0.129	Dec-91	88.1	0.832
Jan-69	73.5	0.429	Jan-92	40.2	0.2
Feb-69	98.9	1.033	Feb-92	109.8	1.08
Mar-69	111.9	1.051	Mar-92	152.6	1.556
Apr-69	198.6	3.352	Apr-92	144	1.836
May-69	78.9	1.384	May-92	88.5	0.972
Jun-69	133.1	1.895	Jun-92	100	0.753
Jul-69	72.4	0.864	Jul-92	100.5	0.589
Aug-69	124.6	1.047	Aug-92	39.6	0.336
Sep-69	84.8	1.065	Sep-92	89	1.077
Oct-69	104.4	1.238	Oct-92	106.8	1.15
Nov-69	144.7	2.135	Nov-92	96	0.791
Dec-69	143.1	2.088	Dec-92	89.3	0.529
Jan-70	117.2	1.621	Jan-93	130.9	1.184
Feb-70	180.7	2.763	Feb-93	139.5	2.593
Mar-70	125.9	1.352	Mar-93	128	3.66
Apr-70	143.3	1.566	Apr-93	148.2	2.88
May-70	129.7	1.653	May-93	86.5	1.208

Jun-70	115.5	1.603	Jun-93	83.4	0.829
Jul-70	95.1	1.219	Jul-93	99.5	1.105
Aug-70	103.5	1.133	Aug-93	54	0.577
Sep-70	90.8	0.918	Sep-93	60.2	0.636
Oct-70	146.2	1.647	Oct-93	106.8	1.138
Nov-70	116.5	2.077	Nov-93	96	0.985
Dec-70	93.5	0.817	Dec-93	122.5	1.728
Jan-71	103.2	1.069	Jan-94	98.2	1.429
Feb-71	166.3	2.166	Feb-94	113.2	1.825
Mar-71	257.5	3.408	Mar-94	175.5	2.375
Apr-71	93	1.905	Apr-94	164.9	2.786
May-71	78.6	0.965	May-94	120.1	2.008
Jun-71	105.5	1.644	Jun-94	122.1	1.587
Jul-71	86.7	1.275	Jul-94	120.6	1.499
Aug-71	112	1.266	Aug-94	143.2	1.714
Sep-71	115.1	1.162	Sep-94	96.5	1.103
Oct-71	115.1	1.495	Oct-94	38.2	0.466
Nov-71	58.3	0.453	Nov-94	110	2.072
Dec-71	61.9	0.729	Dec-94	96.2	0.849
Jan-72	136.8	1.732	Jan-95	48.7	0.269
Feb-72	82.2	1.309	Feb-95	78.7	0.592
Mar-72	231	2.856	Mar-95	112.9	0.931
Apr-72	99.6	1.579	Apr-95	113.7	1.324
May-72	84.6	0.794	May-95	110.2	1.865
Jun-72	141.8	1.431	Jun-95	100.2	1.382
Jul-72	118.9	1.367	Jul-95	101.1	1.243
Aug-72	44.1	0.526	Aug-95	21.9	0.328
Sep-72	76.5	0.446	Sep-95	59.5	0.177
Oct-72	38.8	0.15	Oct-95	138.3	0.575
Nov-72	171.8	2.39	Nov-95	155.1	1.663
Dec-72	111.6	1.16	Dec-95	179.7	2.26
Jan-73	98.2	0.854	Jan-96	120.4	1.52
Feb-73	103.7	1.195	Feb-96	141.2	2.479
Mar-73	73.1	0.586	Mar-96	190.5	2.505
Apr-73	152	2.445	Apr-96	250.8	3.221
May-73	124.2	1.516	May-96	168.1	2.341
Jun-73	69.5	1.177	Jun-96	73.6	1.873
Jul-73	114.9	1.491	Jul-96	162	1.916
Aug-73	118.9	1.475	Aug-96	68.4	0.81
Sep-73	118.7	1.623	Sep-96	92.7	0.764
Oct-73	42.4	0.239	Oct-96	181.2	1.701

Nov-73	78.2	0.282	Nov-96	37.8	0.389
Dec-73	107.9	0.758	Dec-96	63.5	0.342
Jan-74	52.1	0.348	Jan-97	92.6	0.852
Feb-74	132.1	2.284	Feb-97	117	0.892
Mar-74	109.4	1.201	Mar-97	130.8	1.688
Apr-74	112.7	1.827	Apr-97	203.6	2.553
May-74	121.7	1.262	May-97	111.9	1.363
Jun-74	114.3	1.502	Jun-97	52.6	1.017
Jul-74	158.6	1.968	Jul-97	116.4	1.146
Aug-74	98.6	1.082	Aug-97	68.6	0.595
Sep-74	181.4	2.328	Sep-97	50.2	0.528
Oct-74	146.3	1.888	Oct-97	82.7	0.463
Nov-74	154.7	2.13	Nov-97	287.3	2.635
Dec-74	86.4	0.801	Dec-97	93.7	1.026
Jan-75	101	0.523	Jan-98	50.8	0.452
Feb-75	154.3	2.214	Feb-98	191.4	2.512
Mar-75	137.6	1.402	Mar-98	190	2.675
Apr-75	127	1.898	Apr-98	129.1	1.595
May-75	189	2.539	May-98	148	2.303
Jun-75	166.1	2.544	Jun-98	117.7	1.447
Jul-75	158.3	2.894	Jul-98	132.2	1.601
Aug-75	123.8	2.085	Aug-98	62.8	0.756
Sep-75	53.5	0.628	Sep-98	30.4	0.24
Oct-75	191.7	1.879	Oct-98	107.2	1.4
Nov-75	137	1.575	Nov-98	57.7	0.745
Dec-75	55.9	0.69	Dec-98	40.1	0.256
Jan-76	130.7	0.882	Jan-99	151.1	1.439
Feb-76	105.8	0.981	Feb-99	220.5	2.84
Mar-76	89.1	0.819	Mar-99	170.3	3.081
Apr-76	179.3	2.306	Apr-99	208.7	3.82
May-76	133.2	2.465	May-99	186.2	3.206
Jun-76	129.4	1.79	Jun-99	98.5	1.908
Jul-76	164.1	2.144	Jul-99	113	1.398
Aug-76	90.5	1.345	Aug-99	92.3	0.983
Sep-76	72.8	0.784	Sep-99	119.8	1.533
Oct-76	80.6	0.483	Oct-99	80	0.507
Nov-76	113.2	0.533	Nov-99	41.7	0.324
Dec-76	111.2	0.996	Dec-99	187.8	1.914
Jan-77	96.6	1.51	Jan-00	93.1	0.813
Feb-77	113.1	1.114	Feb-00	207	2.867
Mar-77	108.9	0.838	Mar-00	150.5	2.229

Apr-77	187.9	2.138	Apr-00	191	2.851
May-77	76.4	0.771	May-00	223.7	3.444
Jun-77	118.2	1.571	Jun-00	103.1	2.03
Jul-77	67.3	0.816	Jul-00	61.8	0.948
Aug-77	64.5	0.59	Aug-00	68.3	0.653
Sep-77	86.3	0.942	Sep-00	214.1	2.997
Oct-77	103.2	1.396	Oct-00	48.9	0.436
Nov-77	31.2	0.476	Nov-00	35.6	0.107
Dec-77	132.7	0.955	Dec-00	94.9	0.355
Jan-78	59	0.433	Jan-01	151.1	1.427
Feb-78	58.9	0.857	Feb-01	87.1	1.063
Mar-78	165.7	2.151	Mar-01	165.8	2.173
Apr-78	187.5	2.975	Apr-01	123	1.588
May-78	129.9	1.807	May-01	107.6	1.111
Jun-78	139.6	1.84	Jun-01	139.8	1.554
Jul-78	105.4	1.424	Jul-01	94.9	0.945
Aug-78	78.7	0.894	Aug-01	89.3	0.786
Sep-78	143.4	1.738	Sep-01	65.3	0.566
Oct-78	63.5	0.365	Oct-01	104.9	0.129
Nov-78	53.9	0.495	Nov-01	97.4	0.555
Dec-78	145.9	0.911	Dec-01	94.9	0.922
Jan-79	34	0.37	Jan-02	82.7	0.501
Feb-79	71.5	0.49	Feb-02	90.9	0.375
Mar-79	155.4	1.943	Mar-02	116.7	0.861
Apr-79	147.7	2.296	Apr-02	128	1.869
May-79	100.9	1.614	May-02	126.8	1.524
Jun-79	68.9	0.937	Jun-02	57.5	0.844
Jul-79	69.5	0.742	Jul-02	83.4	1.004
Aug-79	108.1	1.041	Aug-02	79.2	0.625
Sep-79	77.6	0.603	Sep-02	88.7	0.222
Oct-79	42.3	0.192	Oct-02	155.1	1.679
Nov-79	56.9	0.377	Nov-02	121.1	1.735
Dec-79	49	0.15	Dec-02	105.1	1.226
Jan-80	118.9	0.815	Jan-03	37.5	0.397
Feb-80	114.7	2.06	Feb-03	46.8	0.338
Mar-80	127	1.29	Mar-03	87	0.637
Apr-80	156.5	2.208	Apr-03	138.5	1.72
May-80	76.6	0.778	May-03	135.3	1.59
Jun-80	83.7	0.835	Jun-03	96.6	1.182
Jul-80	120.1	1.273	Jul-03	71.9	0.979
Aug-80	70.8	0.803	Aug-03	30.9	0.373

Sep-80	44.3	0.634	Sep-03	59.6	0.584
Oct-80	155.2	2.109	Oct-03	85.2	0.481
Nov-80	172.9	2.452	Nov-03	138	1.762
Dec-80	107.8	1.697	Dec-03	98.7	1.116
Jan-81	92	0.812	Jan-04	55.9	0.374
Feb-81	182.9	1.628	Feb-04	117.2	1.09
Mar-81	251	2.776	Mar-04	99.4	0.663
Apr-81	145.1	2.578	Apr-04	174.1	1.959
May-81	123.4	1.169	May-04	126.7	1.529
Jun-81	85.8	1.072	Jun-04	120.2	1.374
Jul-81	87.6	1.25	Jul-04	74.5	1.084
Aug-81	62.3	0.704	Aug-04	54.5	0.492
Sep-81	63.3	0.487	Sep-04	86	1.119
Oct-81	75.2	0.707	Oct-04	84	0.532
Nov-81	27.9	0.269	Nov-04	128.4	1.857
Dec-81	135.8	1.079	Dec-04	140.1	1.539
Jan-82	102.4	1.06	Jan-05	59	0.615
Feb-82	60.8	0.415	Feb-05	146.6	1.717
Mar-82	89.1	0.83	Mar-05	219	3.506
Apr-82	144.1	2.706	Apr-05	115.8	2.601
May-82	178.1	3.048	May-05	91.3	1.27
Jun-82	53.9	0.986	Jun-05	125	1.692
Jul-82	111.4	1.19	Jul-05	40.6	0.668
Aug-82	79.1	0.739	Aug-05	35.7	0.362
Sep-82	118.8	0.993	Sep-05	43.9	0.174
Oct-82	171.6	2.833	Oct-05	55.8	0.725
Nov-82	85.8	1.288	Nov-05	73.6	0.449
Dec-82	186	1.846	Dec-05	210.9	2.861
Jan-83	92.6	1.884	Jan-06	122.7	1.412
Feb-83	104.9	1.343	Feb-06	126.1	1.487
Mar-83	166.6	1.795	Mar-06	174.9	2.254
Apr-83	149.8	2.605	Apr-06	149.1	2.665
May-83	187.8	2.813	May-06	76.7	0.97
Jun-83	59.3	0.958	Jun-06	89.7	1.132
Jul-83	50.5	0.568	Jul-06	40.5	0.569
Aug-83	71.1	0.548	Aug-06	65.7	0.572
Sep-83	56.9	0.315	Sep-06	54.6	0.409
Oct-83	140.5	1.152	Oct-06	57	0.292
Nov-83	77	0.522	Nov-06	190.4	1.489
Dec-83	156.6	1.684	Dec-06	141.5	1.527
Jan-84	92.6	0.524	Jan-07	106.8	0.899

Feb-84	179.2	2.688	Feb-07	36.3	0.316
Mar-84	142.2	2.157	Mar-07	167	1.925
Apr-84	162.6	2.983	Apr-07	170.8	3.075
May-84	102.7	1.775	May-07	107.5	1.418
Jun-84	93	1.203	Jun-07	209.3	2.937
Jul-84	103	0.935	Jul-07	35.3	0.762
Aug-84	70.3	0.618	Aug-07	104.7	1.014
Sep-84	119.9	1.245	Sep-07	58.7	0.531
Oct-84	116.8	1.128	Oct-07	115.4	0.613
Nov-84	82.9	0.747	Nov-07	147.2	1.578
Dec-84	71.4	0.329	Dec-07	107.5	1.158
Jan-85	67.7	0.6	Jan-08	148.2	1.217
Feb-85	43.8	0.313	Feb-08	223.9	3.259
Mar-85	27.5	0.135	Mar-08	158.5	2.249
Apr-85	129.5	0.712	Apr-08	196.8	2.693
May-85	72.6	0.681	May-08	201.4	2.959
Jun-85	90.3	0.874	Jun-08	96.6	1.855
Jul-85	89.8	1.003	Jul-08	109.4	1.467
Aug-85	67.7	0.7	Aug-08	79.6	1.148
Sep-85	53.4	0.456	Sep-08	82.6	0.877
Oct-85	71.4	0.509	Oct-08	152.9	1.42
Nov-85	82.2	0.902	Nov-08	102.3	1.478
Dec-85	127	1.236	Dec-08	70.8	0.674
Jan-86	75	0.662	Jan-09	169.3	1.629
Feb-86	79.3	1.304	Feb-09	110.5	1.136
Mar-86	100.8	1.35	Mar-09	106	1.726
Apr-86	153.5	1.765	Apr-09	127.9	2.344
May-86	90.1	1.239	May-09	74	1.166
Jun-86	54.3	0.544	Jun-09	100.5	1.37
Jul-86	97.4	0.951	Jul-09	81	0.871
Aug-86	26.3	0.458	Aug-09	76.9	0.502
Sep-86	97.6	0.639	Sep-09	85.4	0.286
Oct-86	112.2	0.685	Oct-09	97.2	0.272
Nov-86	101.5	0.961	Nov-09	77	0.386
Dec-86	66.6	0.604	Dec-09	96.7	0.72

Anexo 3.- Datos de Lluvia y caudales de la microcuenca Chanlud

Fecha	Lluvia (mm)	Caudal (m ³ /seg)	Fecha	Lluvia (mm)	Caudal (m ³ /seg)
Jun-88	52.4	2.086	Apr-00	194.4	5.911
Jul-88	90.8	2.079	May-00	306.1	7.094
Aug-88	63.9	2.2	Jun-00	156.3	4.367
Sep-88	62.5	1.219	Jul-00	84.7	2.091
Oct-88	118.2	3.105	Aug-00	64	1.417
Nov-88	178.7	4.377	Sep-00	161.5	6.064
Dec-88	29.6	3.259	Oct-00	98	1.008
Jan-89	143	4.67	Nov-00	27.9	0.274
Feb-89	160.3	4.573	Dec-00	57.4	0.72
Mar-89	163.1	5.56	Jan-01	168.2	2.825
Apr-89	74	2.981	Feb-01	76.5	2.241
May-89	78.9	1.609	Mar-01	132.8	4.415
Jun-89	111.9	3.223	Apr-01	121.9	3.337
Jul-89	97.7	2.976	May-01	122.6	2.36
Aug-89	31.3	0.916	Jun-01	106.4	3.229
Sep-89	113.3	1.44	Jul-01	87.9	2.001
Oct-89	140.2	3.354	Aug-01	106.2	1.652
Nov-89	49.5	0.709	Sep-01	78	1.211
Dec-89	21	0.193	Oct-01	98	0.306
Jan-90	71.3	1.393	Nov-01	94	1.104
Feb-90	84.2	1.892	Dec-01	72.9	1.864
Mar-90	99.8	1.406	Jan-02	74.4	1.059
Apr-90	148.1	4.748	Feb-02	66.9	0.799
May-90	117.2	2.571	Mar-02	136	1.708
Jun-90	103.5	2.444	Apr-02	172	3.778
Jul-90	63.6	2.132	May-02	131	3.177
Aug-90	71.2	1.409	Jun-02	109	1.825
Sep-90	35.2	0.716	Jul-02	147	2.069
Oct-90	94.2	4.383	Aug-02	112	1.326
Nov-90	114.1	2.454	Sep-02	43.2	0.498
Dec-90	49.9	1.116	Oct-02	137	3.348
Jan-91	41.7	0.695	Nov-02	122	3.581
Feb-91	74.3	1.898	Dec-02	82.6	2.576

Mar-91	127.9	2.704	Jan-03	53.3	0.88
Apr-91	88.3	1.383	Feb-03	69.6	0.73
May-91	75	1.919	Mar-03	83.6	1.293
Jun-91	99.3	2.1	Apr-03	171	3.475
Jul-91	95.7	2.105	May-03	247	3.268
Aug-91	57.3	1.725	Jun-03	125	2.484
Sep-91	80.7	1.447	Jul-03	142	2.056
Oct-91	101	1.344	Aug-03	66.2	0.82
Nov-91	85.3	3.52	Sep-03	83.3	1.208
Dec-91	86.5	1.765	Oct-03	90.2	1.001
Jan-92	36.1	0.464	Nov-03	139	3.55
Feb-92	70	2.166	Dec-03	158	2.342
Mar-92	116.2	3.153	Jan-04	50.3	0.828
Apr-92	121.9	3.794	Feb-04	71.9	2.22
May-92	71.3	2.065	Mar-04	150	1.378
Jun-92	102.1	1.592	Apr-04	167	3.967
Jul-92	70.6	1.251	May-04	154	3.191
Aug-92	54.3	0.728	Jun-04	195	2.883
Sep-92	81.8	2.18	Jul-04	120	2.275
Oct-92	100	2.356	Aug-04	85.1	1.07
Nov-92	70	1.661	Sep-04	110	2.293
Dec-92	50	1.118	Oct-04	128	1.128
Jan-93	94.3	2.389	Nov-04	139	3.742
Feb-93	173.2	5.285	Dec-04	119	3.207
Mar-93	186.9	7.474	Jan-05	48.9	1.336
Apr-93	128.5	6.046	Feb-05	123	3.53
May-93	104.9	2.667	Mar-05	195	7.12
Jun-93	181.3	1.803	Apr-05	190	5.473
Jul-93	108	2.296	May-05	148	2.752
Aug-93	80.8	1.24	Jun-05	167	3.567
Sep-93	63.8	1.332	Jul-05	95.1	1.469
Oct-93	98.4	2.313	Aug-05	72.7	0.792
Nov-93	55.2	2.032	Sep-05	62.8	0.39
Dec-93	109	3.539	Oct-05	82.7	1.45
Jan-94	84.3	2.969	Nov-05	127	0.937
Feb-94	71.3	3.809	Dec-05	169	5.732
Mar-94	149.2	4.884	Jan-06	184	3.018
Apr-94	189	5.768	Feb-06	90.4	3.162
May-94	152.1	4.229	Mar-06	150	4.633

Jun-94	76.2	3.382	Apr-06	192	5.522
Jul-94	98.5	3.158	May-06	102	2.144
Aug-94	142.4	3.601	Jun-06	137	2.386
Sep-94	95.3	2.372	Jul-06	83.5	1.23
Oct-94	49.6	1.011	Aug-06	105	1.2
Nov-94	121.7	4.192	Sep-06	89.6	0.869
Dec-94	110.1	1.822	Oct-06	61.6	0.621
Jan-95	30.6	0.608	Nov-06	188	2.96
Feb-95	87.4	1.215	Dec-06	98.2	3.131
Mar-95	104.2	1.886	Jan-07	122	1.916
Apr-95	118.4	2.719	Feb-07	44.3	0.712
May-95	142.2	3.823	Mar-07	182	3.832
Jun-95	91.2	2.907	Apr-07	199	6.278
Jul-95	80.4	2.607	May-07	114	3.054
Aug-95	12.3	0.743	Jun-07	322	6.027
Sep-95	35.8	0.4	Jul-07	25.6	1.712
Oct-95	82.4	1.157	Aug-07	150	2.128
Nov-95	121.6	3.323	Sep-07	88.1	1.148
Dec-95	137.7	4.625	Oct-07	146	1.275
Jan-96	71.6	3.233	Nov-07	219	3.184
Feb-96	103	5.121	Dec-07	125	2.415
Mar-96	135.3	5.189	Jan-08	91.2	2.527
Apr-96	124	6.645	Feb-08	194	6.62
May-96	105.9	4.944	Mar-08	157	4.732
Jun-96	102.2	4.002	Apr-08	149	5.597
Jul-96	88.2	4.02	May-08	252	6.134
Aug-96	64.2	1.795	Jun-08	152	4.011
Sep-96	71.1	1.615	Jul-08	184	3.139
Oct-96	98	3.481	Aug-08	140	2.45
Nov-96	99.5	0.864	Sep-08	102	1.867
Dec-96	74.2	0.727	Oct-08	186	2.911
Jan-97	71.6	1.7	Nov-08	133	3.07
Feb-97	103	1.855	Dec-08	99.4	1.461
Mar-97	135.3	3.447	Jan-09	166	3.306
Apr-97	124	5.232	Feb-09	117	2.419
May-97	105.9	2.923	Mar-09	162	3.557
Jun-97	102.2	2.174	Apr-09	162	4.835
Jul-97	88.2	2.397	May-09	111	2.502
Aug-97	64.2	1.281	Jun-09	139	2.863

Sep-97	71.1	1.111	Jul-09	131	1.85
Oct-97	98	0.964	Aug-09	106	1.077
Nov-97	99.5	5.297	Sep-09	70.9	0.624
Dec-97	74.2	2.213	Oct-09	68.1	0.569
Jan-98	71.6	0.988	Nov-09	94.5	0.787
Feb-98	103	5.093	Dec-09	92.9	1.458
Mar-98	135.3	5.504	Jan-10	56.5	0.579
Apr-98	124	3.438	Feb-10	161	2.76
May-98	105.9	4.773	Mar-10	90.4	1.566
Jun-98	102.2	3.085	Apr-10	149	3.41
Jul-98	88.2	3.331	May-10	160	3.799
Aug-98	64.2	1.635	Jun-10	163	4.952
Sep-98	71.1	0.546	Jul-10	152	4.451
Oct-98	98	2.802	Aug-10	87.6	1.812
Nov-98	99.5	1.574	Sep-10	79.1	1.31
Dec-98	74.2	0.571	Oct-10	68.6	0.411
Jan-99	71.6	2.854	Nov-10	77.3	1.403
Feb-99	103	5.793	Dec-10	122	3.034
Mar-99	135.3	6.334	Jan-11	133	
Apr-99	124	7.874	Feb-11	135	
May-99	105.9	6.709	Mar-11	107	
Jun-99	102.2	4.127	Apr-11	214	
Jul-99	88.2	3.002	May-11	601	
Aug-99	64.2	2.111	Jun-11	100	
Sep-99	71.1	3.173	Jul-11	243	
Oct-99	98	1.106	Aug-11	79.9	
Nov-99	99.5	0.698	Sep-11	132	
Dec-99	74.2	3.813	Oct-11	96.6	
Jan-00	102.5	1.729	Nov-11	153	
Feb-00	213.8	5.818	Dec-11	90.7	
Mar-00	177.6	4.652			

Anexo 4.- Descripción sistemática de la realización de RNAs en NeuralTools 6.3

Al seleccionar NeuralTools, automáticamente se abre la ventana de Microsoft Excel, con una sub-ventana de NeuralTools (Figura 19), en el que se puede encontrar una ayuda sobre este programa y varios ejemplos que nos ayuda a determinar el funcionamiento del programa.

Figura 19.- Ventana inicial de NeuralTools 6.3

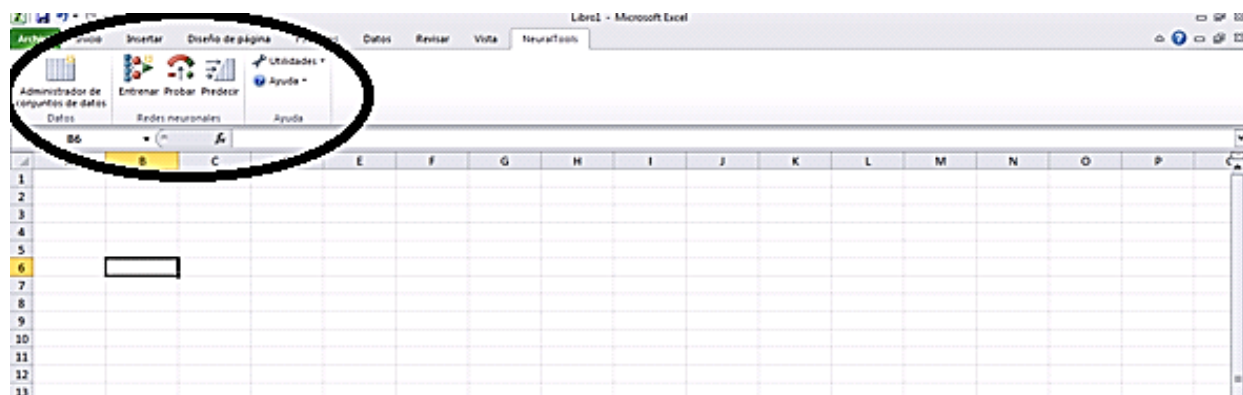


Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Al cerrar esta sub-ventana, en la barra de menú de la hoja de Excel ya aparece el programa en mención (Figura 20), con sus diferentes herramientas para la construcción de las RNAs. Dentro de estas herramientas encontramos los iconos de :
Administración de conjunto de datos, entrenar, probar y predecir.

Figura 20.- Iconos para la aplicación de las RNAs



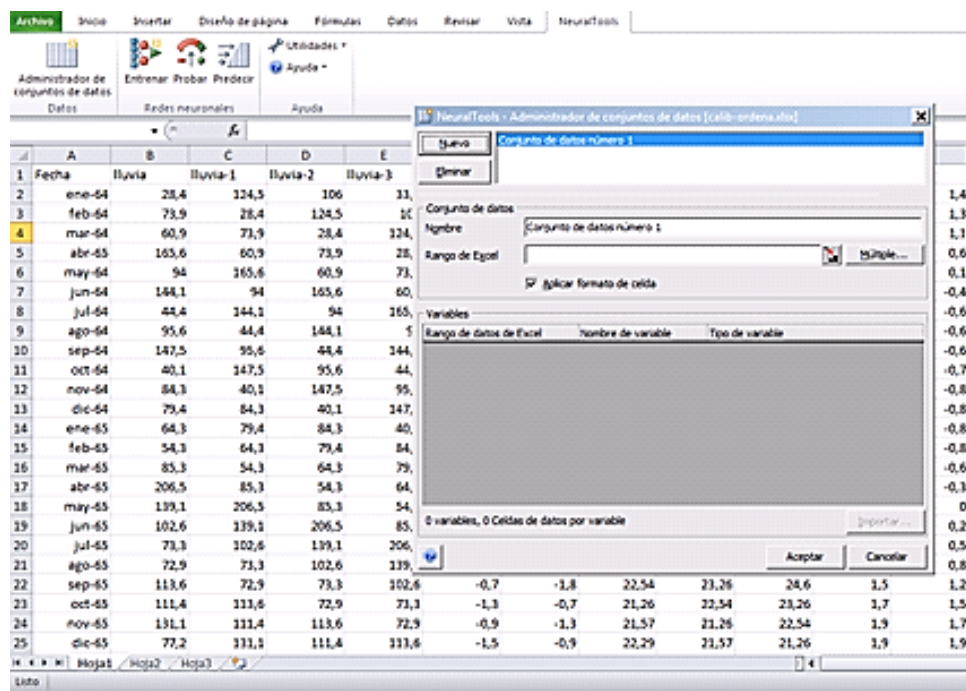
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Administración de conjunto de datos

Aquí se selecciona el conjunto de datos con el que se va a realizar la investigación. Luego de seleccionar este icono, nos aparece una ventana (Figura 21), con varias opciones para la determinación del conjunto de datos. En la opción “Nuevo” no ayuda a crear un conjunto de información que nos servirá para el entrenamiento para luego en el “rango de Excel”, seleccionar las columnas a utilizar.

Figura 21.- Ventana de la opción "Administrador del Conjunto de Datos"



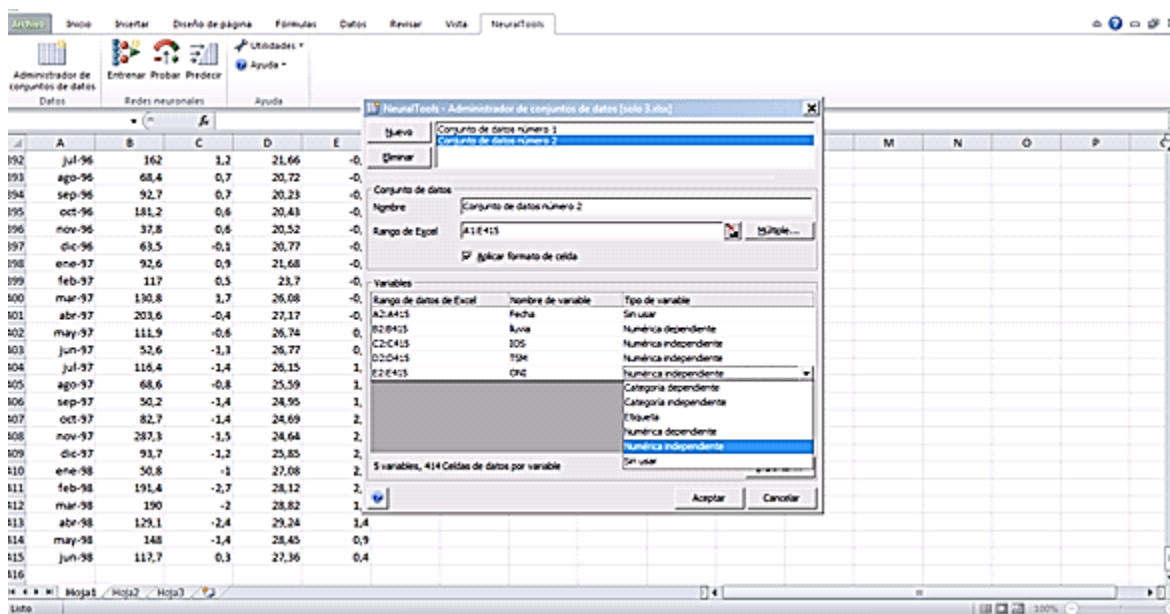
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Al ya tener las columnas para el análisis, procedemos a determinar el tipo de variable (Figura 22). En el programa se pueden clasificar en 4 tipos de variables que son: numéricas independientes, dependientes y categorías independientes, dependientes (por ejemplo: Si o No, tipos de colores). NeuralTools tiene la capacidad de determinar por sí mismo el tipo de variable de cada columna ingresada; pero también, el investigador tiene la capacidad sustituir los tipos de variables por sus propias selecciones. El objetivo principal de la distinción del tipo de variable es para la determinación de la variable a utilizar; es decir la variable a predecir vendría a ser la

numérica dependiente y los variables que va a ayudar en la predicción son las numéricas independientes. También nos permite la no utilización de alguna variable dentro del análisis al colocar “no usar”.

Figura 22.- Determinación de tipo de variable



Fuente: (NeuralTools 6.3, 2014)

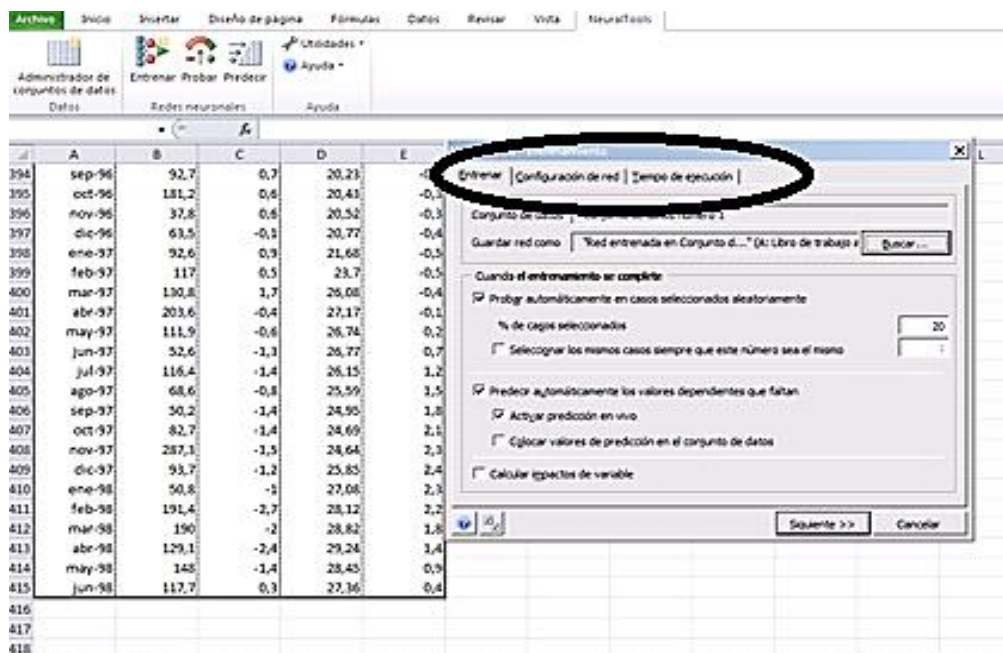
Realizado por: (Quito N, 2014)

Dentro de nuestra investigación, la numérica dependiente vendría a ser la lluvia, las numéricas independientes serían los datos de cada prototipo planteado y la variable sin usar es la fecha. Luego de ya tener realizado todo este proceso solo colocamos aceptar y el conjunto de datos está listo para el entrenamiento.

Entrenamiento de la red

En la opción entrenar (Figura 23), se da todas la condiciones para la calibración de la red a utilizarse. Esta ventana está compuesta por 3 pestañas para el entrenamiento, que son: Entrenar, Configuración de la red y Tiempo de ejecución.

Figura 23.- Opciones para el entrenamiento de la red



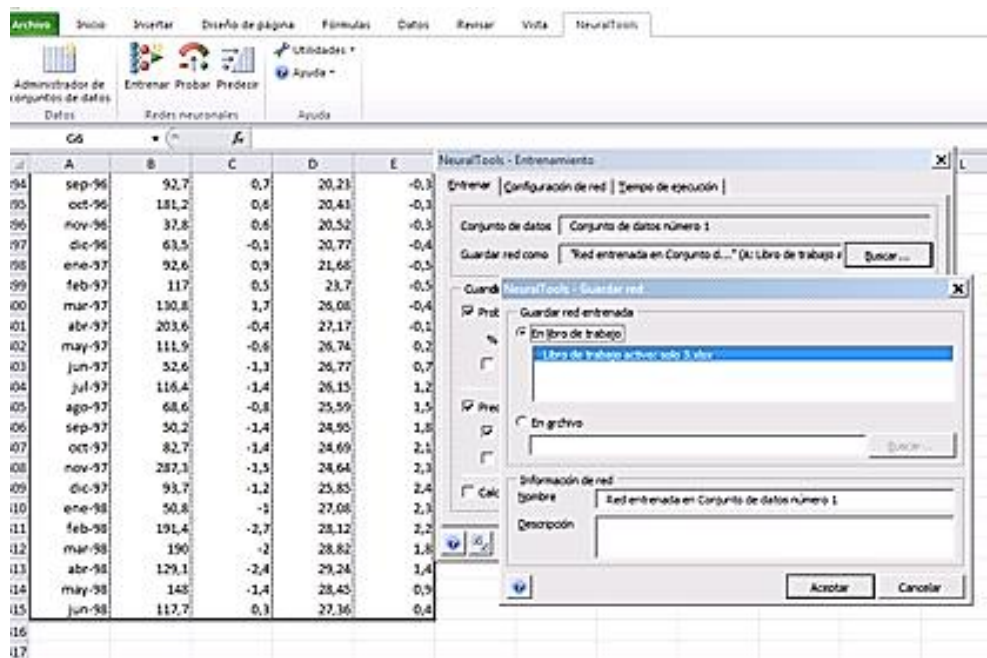
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Entrenamiento

La pestaña “entrenar”, en la primera parte, permite determinar el conjunto que va a ser utilizado y también la capacidad de guardar la red entrenada. Esta red entrenada, puede ser guarda en el libro que se está trabajando o en un archivo para que luego sea utilizado en la validación de esta red (Figura 24). El archivo de entrenamiento tiene una extensión .ntf.

Figura 24.- Opciones para guardar la red entrenada



Fuente: (NeuralTools 6.3, 2014)

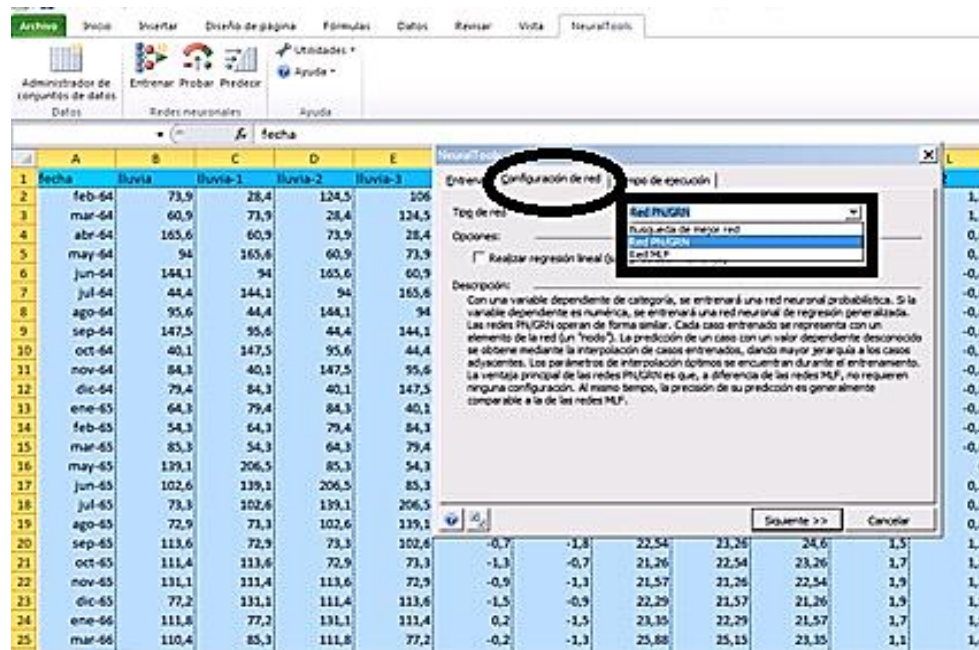
Realizado por: (Quito N, 2014)

La segunda parte de la opción “entrenar” (Figura 23), permite ya realizar la validación y predicción en la red entrenada. La validación se lo realiza a través de “probar automáticamente en casos seleccionados”; es decir aquí se le puede dar una cierto porcentaje de datos para la validación de la red. Para la predicción se activa la opción, “predecir automáticamente los valores dependientes que faltan”, y es así que se puede tener de una manera rápida el entrenamiento, validación y predicción de una red; pero para el presente estudio en esta sección “entrenar” solo se calibrará a la red debido a que en un principio ya se designó un conjunto de datos para el entrenamiento y el otro para la validación, es por eso que la segunda parte de esta pestaña no se habilitará. También permite determinar el impacto de cada uno de las variables independientes en el entrenamiento de la red.

La segunda pestaña del entrenamiento de la red, es la configuración de la red que nos permite determinar el modelo de la red a trabajar (Figura 25). NeuralTools tiene 3 tipos de red que pueden ser seleccionados y son: red neuronal de perceptrón multicapas o de capas múltiples (MLF), red neuronal probabilística (PN) y red

neuronal de regresión generalizada (GRNN). El funcionamiento de estos modelos ya fue explicado con anterioridad y ahora solo explicaremos el mecanismo a seguir dentro del programa.

Figura 25.- Selección de la arquitectura de la red



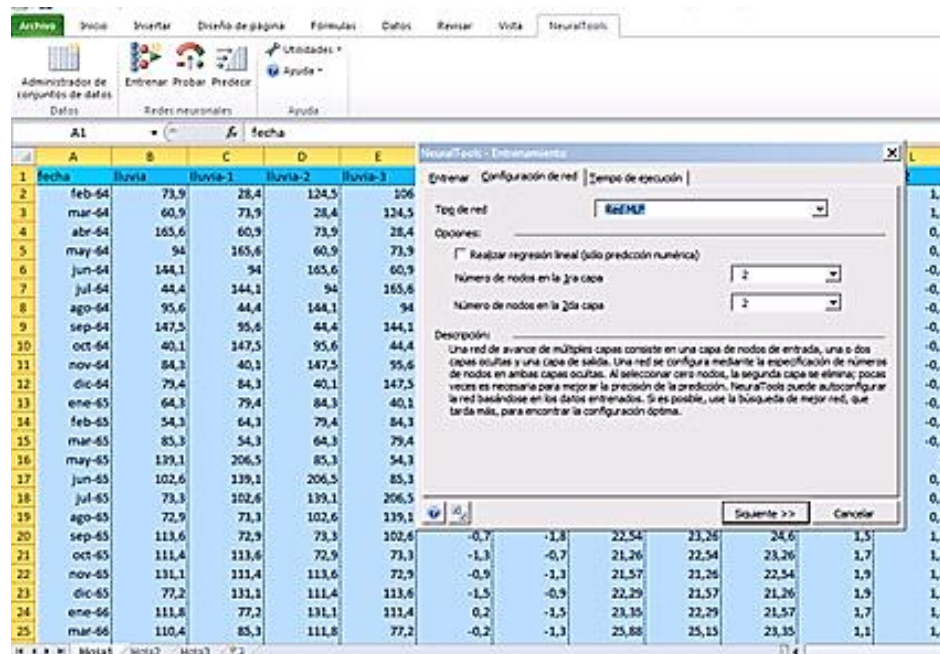
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

NeuralTools une a las redes PN y GRNN en una sola (PN/GRNN), debido a que tienen funcionamiento idéntico. Este tipo de redes no necesitan de selección de opciones adicionales para el entrenamiento. Si los datos tienen valores de salida numérica el programa elige para el entrenamiento a la red GRNN y si tienen valores de salida de categoría se entrenará con una red PN.

La red MLF (Figura 26), el software tiene 2 capas ocultas y que deja al criterio del elegir el número de neuronas en cada capa. La función de activación en las capas ocultas ya viene determinada por el programa y es la tangente hiperbólica; mientras para la capa de salida utiliza la función de identidad

Figura 26.- Condiciones de la red MLF



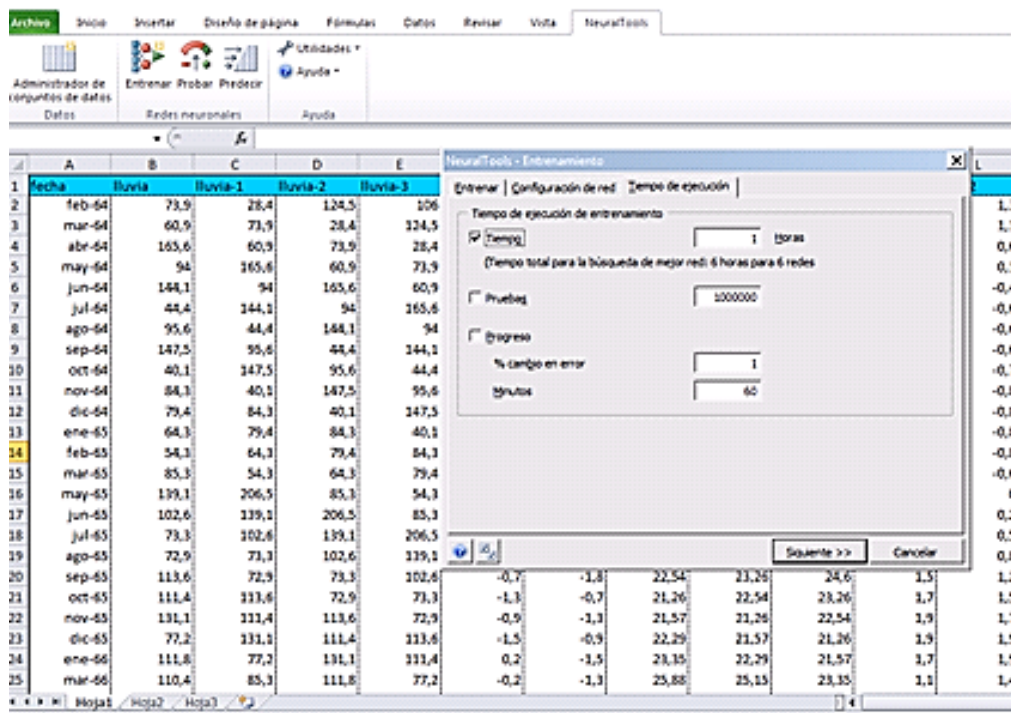
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Tiempo de ejecución

Dentro de esta pestaña se da las diferentes opciones para que termine el entrenamiento (Figura 27). La primera opción dar un determinado tiempo en horas para que se entrene la red. La segunda es a través de un número determinado de pruebas y el último es una combinación de los 2 anteriores que se basa en el porcentaje de cambio del error en un determinado tiempo. Para nuestro estudio se utilizó 1 hora de entrenamiento de cada red.

Figura 27.- Condiciones para la finalización del entrenamiento

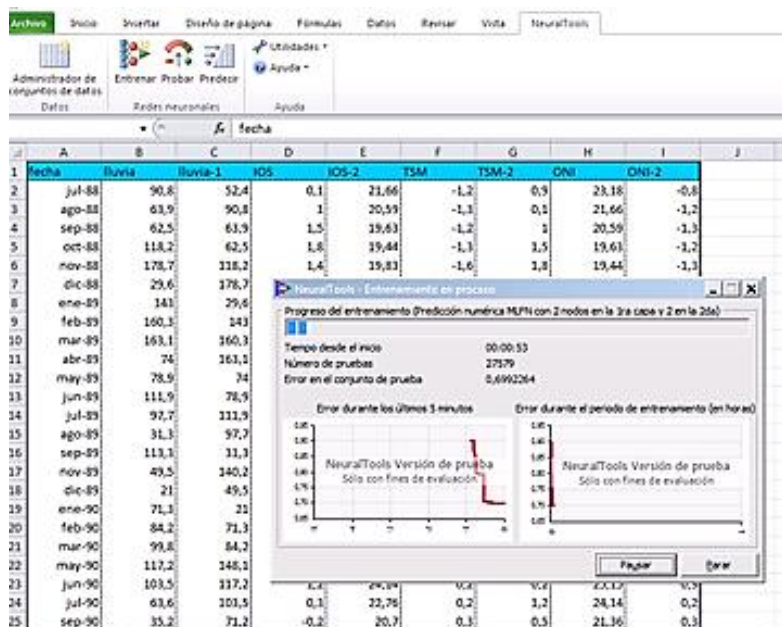


Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Cuando se ha terminado de realizar todo lo descrito y al aceptar podemos ver que en la pantalla aparece un recuadro (Figura 28), en donde se puede ver como el error va disminuyendo y el tiempo de entrenamiento de la red.

Figura 28.- Verificación del entrenamiento



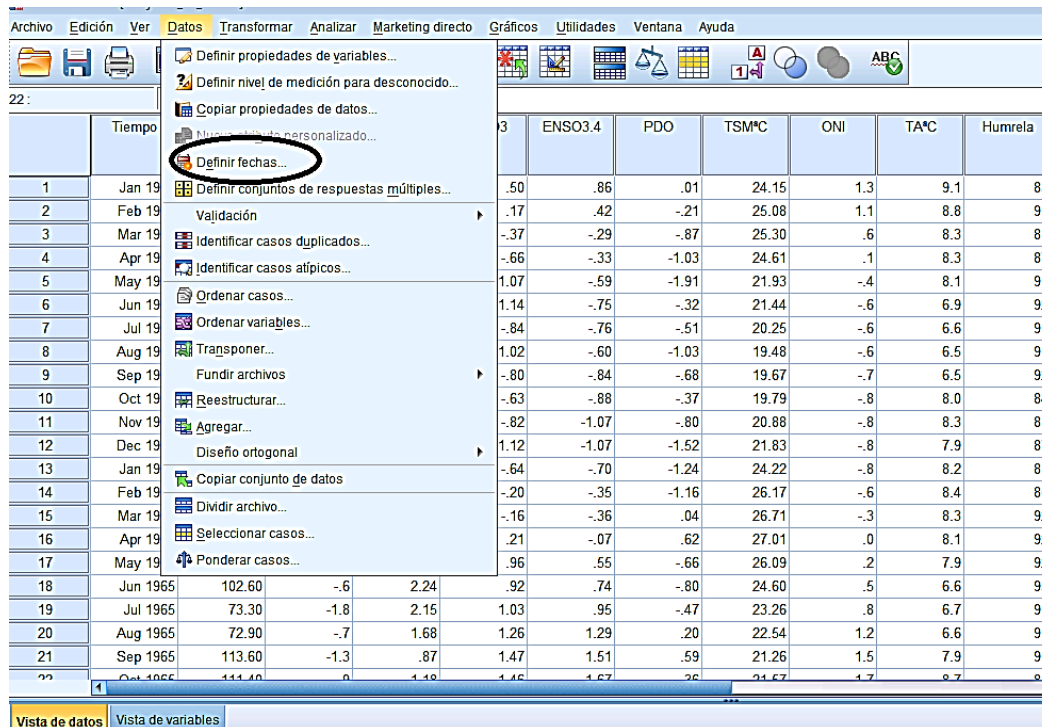
Fuente: (NeuralTools 6.3, 2014)

Realizado por: (Quito N, 2014)

Anexo 6 Determinación de modelo ARIMA en IBM SPSS Statistics 20.0

Para comenzar con la predicción dentro de este software, se debe definir las fechas desde cuando comienza la serie de tiempo. Para ello seleccionamos la opción “datos” (Figura 29) y dentro de ella se encuentra la sección definir fechas.

Figura 29.- Definición de fechas de conjunto de análisis

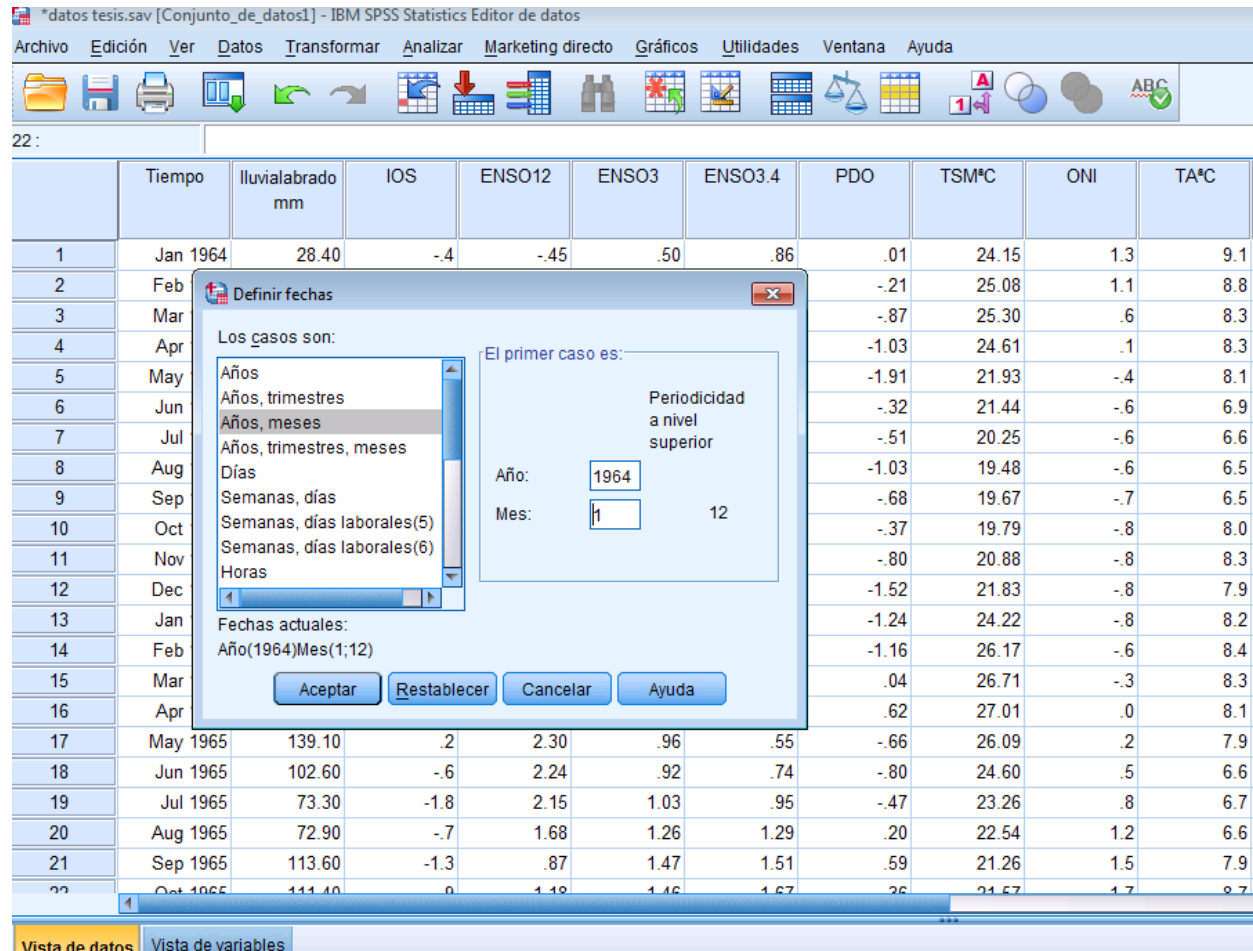


Fuente (IBM SPSS Statistics 20.0, 2011)

Realizado por: (Quito N, 2014)

Esta opción el programa permite seleccionar el tiempo del conjunto de información. Es decir si los datos que van a ser analizados se encuentran: mensualmente, anual, trimestral, etc. También tenemos que especificar la fecha de inicio de la serie temporal (Figura 30). Por ejemplo para la zona de El Labrado, el tiempo sería mensualmente y el inicio sería en enero de 1964.

Figura 30.- Determinación del formato de las fechas

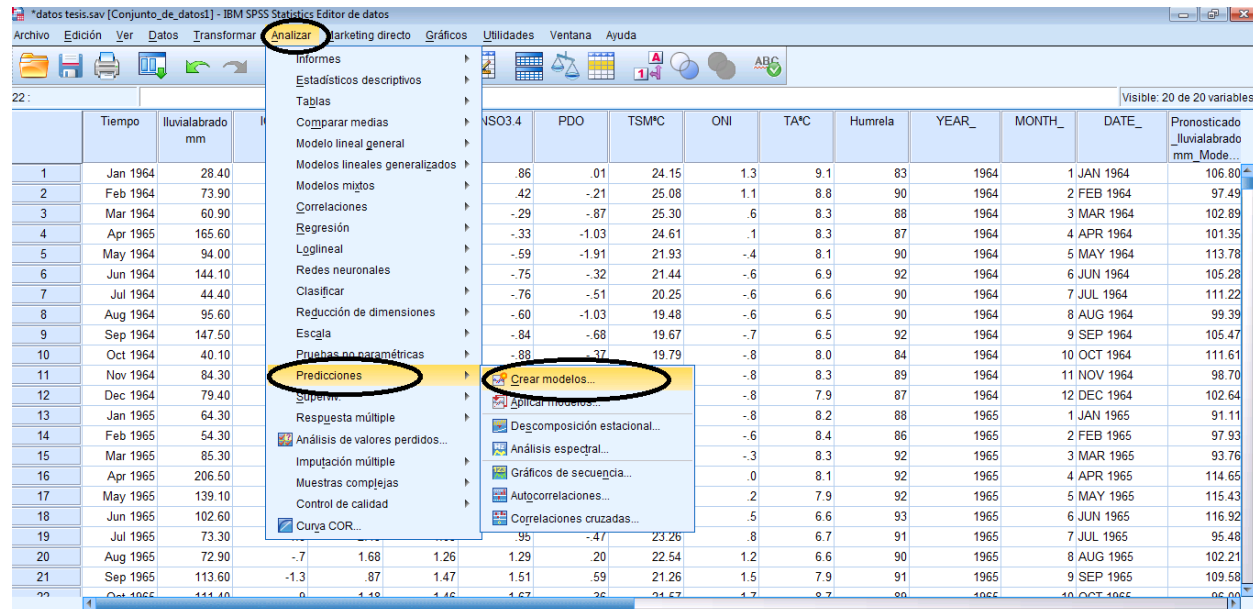


Fuente (IBM SPSS Statistics 20.0, 2011)

Realizado por: (Quito N, 2014)

Ahora ya se puede comenzar con creación del modelo; en el menú “Analizar” se despliega varias opciones para seleccionar (Figura 31), pero el que debemos seleccionar es la alternativa “predicción”, seguido de “crear modelos”.

Figura 31.- Creación del modelo



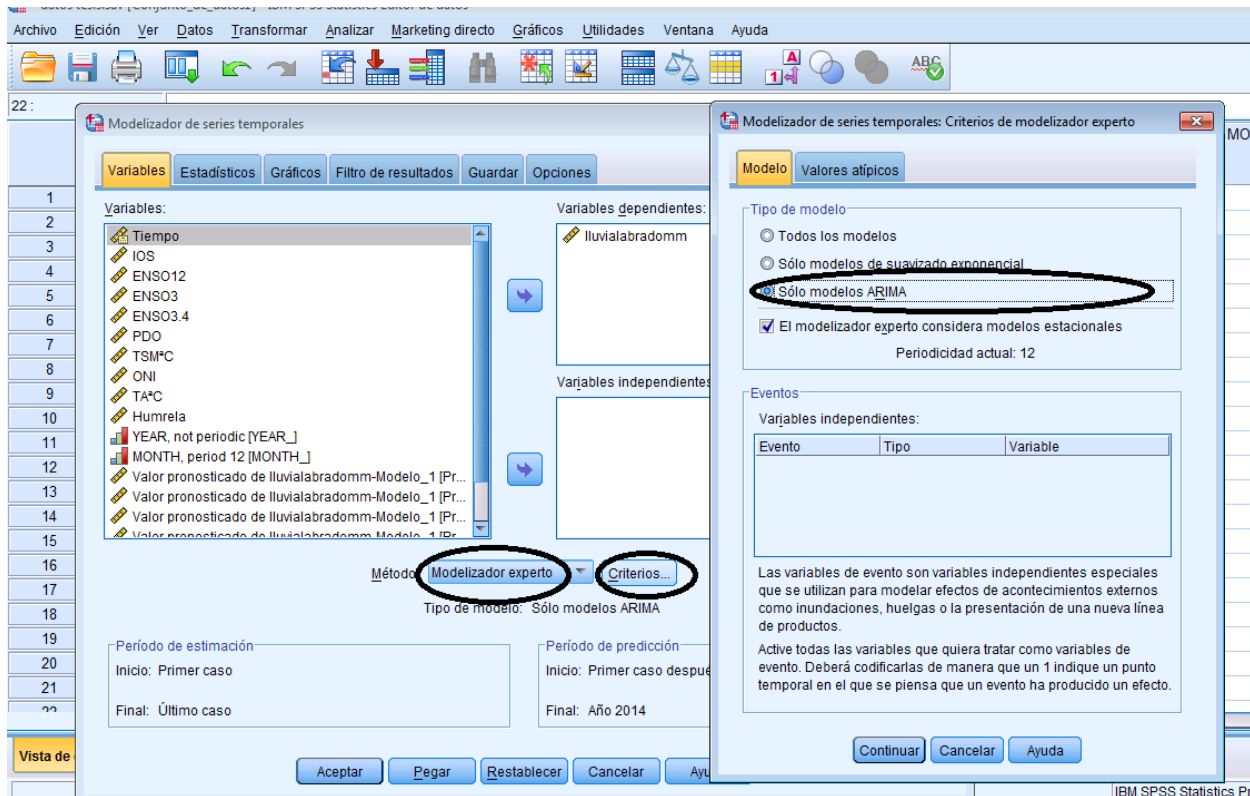
Fuente (IBM SPSS Statistics 20.0, 2011)

Realizado por: (Quito N, 2014)

Dentro de esta alternativa podemos ver que este software, puede no solo generar modelos ARIMA sino que también genera modelos con suavizado exponencial.

En la pestaña “variables” (Figura 32), determinamos la variable a trabajar que en este caso sería lluvia, seguido del modelo a utilizar (ARIMA, Suavizado Exponencial o modelo experto). En la presente investigación se seleccionará el modelo experto debido a que ayuda a determinar el que mejor se ajusta a la información. Cabe destacar que el modelo seleccionado debe ser el ARIMA, para ello en la opción “criterios” especificamos que solo queremos modelos ARIMA.

Figura 32.- Selección del modelo ARIMA



Fuente (IBM SPSS Statistics 20.0, 2011)

Realizado por: (Quito N, 2014)

En la pestaña “Estadísticos”, podemos seleccionar varios parámetros que son de utilidad para determinar el rendimiento del modelo como es el caso de los errores que serán utilizados en el próximo capítulo para definir el mejor modelo. Otras pestaña importante son la de guardar y opciones. La sección “guardar”, permite almacenar lo pronosticado en la hoja de trabajo y en la sección “opciones”, se determina hasta que año se quiere tener información pronosticada.